



ΠΑΝΕΠΙΣΤΗΜΙΟ
ΠΑΤΡΩΝ
UNIVERSITY OF PATRAS

Πολυτεχνική Σχολή
Τμήμα Μηχανικών Η/Υ & Πληροφορικής

Διπλωματική Εργασία

Τεμαχισμός δικτύου 5G με χρήση τεχνικών μη εποπτευόμενης μάθησης για τη βελτίωση της ανάθεσης πόρων

ΔΑΜΙΑΝΟΣ ΔΙΑΣΑΚΟΣ
Α.Μ. 1084632

Επιβλέπων
Καθηγητής Χρήστος Μπούρας

Μέλος Επιτροπής Αξιολόγησης
Καθηγητής Κυριάκος Βλάχος

Μέλος Επιτροπής Αξιολόγησης
Καθηγητής Ιωάννης Γαροφαλάκης

Πάτρα, 2025

© Copyright συγγραφέας ΔΑΜΙΑΝΟΣ ΔΙΑΣΑΚΟΣ, 2025

© Copyright θέματος Χρήστος Ι. Μπούρας

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Η έγκριση της διπλωματικής εργασίας από το Τμήμα Μηχανικών Ηλεκτρονικών Υπολογιστών & Πληροφορικής του Πανεπιστημίου Πατρών δεν υποδηλώνει απαραίτητως και αποδοχή των απόψεων του συγγραφέα εκ μέρους του Τμήματος.

Ευχαριστίες

Θα ήθελα να εκφράσω την ειλικρινή μου ευγνωμοσύνη στον υπεύθυνο καθηγητή της διπλωματικής μου εργασίας και Πρύτανη του Πανεπιστημίου Πατρών, κύριο Χρήστο Μπούρα, για τη συνεχή υποστήριξη και καθοδήγηση που μου παρείχε σε κάθε στάδιο της εκπόνησης αυτής της μελέτης.

Ευχαριστώ θερμά επίσης τον Δρ. Βασίλειο Κόκκινο για τις πολύτιμες συμβουλές και υποδείξεις του, οι οποίες συνέβαλαν ουσιαστικά στην ολοκλήρωση της εργασίας.

Ευχαριστώ την οικογένειά μου για τη διαρκή στήριξή της, καθώς και τους συμφοιτητές, φίλους, δασκάλους και καθηγητές μου, που μου παρείχαν διδασκαλία και καθοδήγηση σε κάθε στάδιο της πορείας.

Περίληψη

Η παρούσα διπλωματική εργασία διερευνά πώς η τμηματοποίηση του δικτύου μπορεί να χρησιμεύσει ως πλαίσιο για τη βελτίωση της ανάθεσης πόρων σε συστήματα 5G μέσω τεχνικών μη εποπτευόμενης μηχανικής μάθησης (MM). Ο τεμαχισμός δικτύου διαμερίζει την κοινή υποδομή σε εικονικά τμήματα προσαρμοσμένα σε διαφορετικά προφίλ υπηρεσιών -όπως η ενισχυμένη κινητή ευρυζωνικότητα, η εξαιρετικά αξιόπιστη χαμηλή καθυστέρηση, το μαζικό Internet of Things (IoT) και το Vehicle-to-everything (V2X)- και παρέχει μια δομή εντός της οποίας μπορεί να βελτιωθεί η κατανομή πόρων. Τέσσερις αλγόριθμοι ομαδοποίησης K-means, Gaussian Mixture Model (GMM), Density-Based Spatial Clustering of Applications with Noise (DBSCAN) και Φασματική Ομαδοποίηση (Spectral Clustering) υλοποιούνται και συγκρίνονται με Τυχαία και Βασιζόμενα σε Κανόνες σχήματα χρησιμοποιώντας ένα συνθετικό σύνολο δεδομένων χρηστών. Κάθε προσέγγιση αξιολογείται ως προς την αποτελεσματικότητα της χρήσης των πόρων, τη δικαιοσύνη της κατανομής, τη συμμόρφωση με την καθυστέρηση και μια συνολική μετρική κατανομής αποτελεσματικότητας. Τα αποτελέσματα δείχνουν ότι η μέθοδος Spectral Clustering παρέχει την πιο ισορροπημένη βελτιστοποίηση σε όλα τα κριτήρια, αποτυπώνοντας πολύπλοκα πρότυπα ζήτησης, ενώ η GMM μεγιστοποιεί την χρήση πόρων και η κατανομή βάσει κανόνων εξασφαλίζει την υψηλότερη δικαιοσύνη. Οι K-means και DBSCAN αναδεικνύονται ως αποτελεσματικές, χαμηλής πολυπλοκότητας εναλλακτικές λύσεις με σταθερή συνολική απόδοση. Αυτά τα ευρήματα αναδεικνύουν ότι η αντιμετώπιση του τεμαχισμού με γνώμονα τη MM ενισχύει σημαντικά τη διαχείριση των πόρων 5G.

Abstract

This thesis explores how network slicing can serve as a framework for enhancing resource assignment in 5G systems through unsupervised machine-learning techniques. Network slicing partitions shared infrastructure into virtual segments tailored to different service profiles—such as enhanced mobile broadband, ultra-reliable low-latency, massive Internet of Things (IoT) and Vehicle-to-everything (V2X)—and provides a structure within which resource allocation can be refined. Four clustering algorithms K-means, Gaussian Mixture Model (GMM), Density-Based Spatial Clustering of Applications with Noise (DBSCAN) and Spectral Clustering are implemented and benchmarked against Random and Rule-Based schemes using a synthetic user dataset. Each approach is assessed on resource utilization efficiency, fairness of distribution, latency compliance and an overall allocation-efficiency metric. Results indicate that the method Spectral Clustering delivers the most balanced improvement across all criteria by capturing complex demand patterns, while GMM maximizes resource utilization and rule-based allocation ensures the highest fairness. K-means and DBSCAN emerge as efficient, low-complexity alternatives with solid overall performance. These findings demonstrate that treating slicing as a dynamic, machine-learning-driven mechanism significantly enhances 5G resource management.

Περιεχομενα

1. Εισαγωγή	1
1.1 Σημασία του προβλήματος.....	1
1.2 Στόχοι της Εργασίας	2
1.3 Μεθοδολογία Προσέγγισης.....	3
1.4 Συνεισφορά	4
1.5 Διάρθρωση της Διπλωματικής Εργασίας.....	4
2. Εισαγωγή στα Δίκτυα Κινητών Επικοινωνιών και στην Τεχνολογία 5G	6
2.1 Εισαγωγή στα δίκτυα επικοινωνίας	6
2.1.1 Τύποι δικτύων επικοινωνίας	6
2.1.2 Βασικές λειτουργίες των δικτύων επικοινωνίας	7
2.2 Εξέλιξη των κινητών δικτύων.....	7
2.2.1 Πρώτη γενιά (1G).....	8
2.2.2 Δεύτερη γενιά (2G).....	8
2.2.3 Τρίτη γενιά (3G).....	9
2.2.4 Τέταρτη γενιά (4G)	9
2.2.5 Πέμπτη γενιά και μετά (5G & beyond).....	10
2.3 Βασικές 5G τεχνολογίες.....	11
2.3.1 Χιλιοστομετρικά κύματα (mmWave)	11
2.3.2 Massive MIMO (Multiple Input Multiple Output)	11
2.3.3 Διαμόρφωση Δέσμης (Beamforming)	12
2.3.4 Παρυφοϋπολογιστική (Edge Computing).....	12
2.3.5 Τεμαχισμός δικτύου (Network Slicing)	13
3. Τεχνικές Κατανομής Πόρων στα Δίκτυα 5G	14
3.1 Εισαγωγή στο πρόβλημα της κατανομής πόρων	14
3.2 Λειτουργία Κατανομής Πόρων στα Δίκτυα 5G.....	14
3.3 Παράγοντες που επηρεάζουν την κατανομή πόρων.....	16
3.4 Παραδοσιακές τεχνικές κατανομής πόρων	17
3.5 Κατανομή Πόρων υπό Συνθήκες Παρεμβολών και Ετερογένειας.....	18
3.6 Παραδοσιακές Προσεγγίσεις Κατανομής Πόρων σε Περιβάλλον Sliced Δικτύων 5G	20
3.7 Η Ανάγκη για Ευφυείς Τεχνικές Κατανομής	20
4. Εισαγωγή στη Μηχανική Μάθηση και τις Εφαρμογές της στα Δίκτυα 5G	22
4.1 Τι είναι η Μηχανική Μάθηση (MM).....	22
4.2 Εποπτευόμενη Μάθηση (Supervised Learning)	23

4.2.1	Γραμμική Παλινδρόμηση (Linear Regression)	23
4.2.2	Δέντρα Απόφασης και Τυχαία Δάση	24
4.2.3	Support Vector Machines (SVM)	25
4.2.4	Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks)	26
4.3	Μη Εποπτευόμενη Μάθηση (Unsupervised Learning)	28
4.3.1	K-Means Clustering	28
4.3.2	Gaussian Mixture Models (GMM)	29
4.3.3	Density-Based Spatial Clustering of Applications with Noise (DBSCAN)	30
4.3.4	Φασματική Ομαδοποίηση (Spectral Clustering)	31
4.4	Ενισχυτική Μάθηση (Reinforcement Learning)	32
4.4.1	Q-Learning	33
4.4.2	Deep Q Networks (DQN)	34
4.4.3	Proximal Policy Optimization (PPO)	35
5.	Πειραματικά Αποτελέσματα	37
5.1	Περιγραφή Πειραματικής Διαδικασίας	37
5.1.1	Υλοποίηση του Πειράματος	37
5.2	Αλγόριθμοι Μη Εποπτευόμενης Μάθησης	38
5.2.1	K-means	38
5.2.2	Gaussian Mixture Models (GMM)	42
5.2.3	Density-Based Spatial Clustering of Applications with Noise (DBSCAN)	45
5.2.4	Φασματική Ομαδοποίηση (Spectral Clustering)	47
5.3	Άλλες Μέθοδοι	50
5.3.1	Τυχαία Κατανομή	50
5.3.2	Μέθοδος Βάσει Κανόνων	51
5.4	Τεχνικές Λεπτομέρειες Υλοποίησης	52
5.5	Μετρικές Αξιολόγησης	52
5.6	Αποτελέσματα	52
6.	Σύνοψη Εργασίας και Προοπτικές	56
6.1	Σύνοψη της Εργασίας	56
6.2	Μελλοντικές Προοπτικές	57
Παραρτήμα Α: Κώδικας Πειραμάτων		59
Ευρετήριο		69
Βιβλιογραφία- Αναφορές		70
Σύντομο Βιογραφικό Συγγραφέα		74

Λίστα Εικονών

Εικόνα 1: Η εξέλιξη της κυψελοειδούς επικοινωνίας.....	10
Εικόνα 2: Resource Grid στο 5G NR	15
Εικόνα 3: Βασικές Κατηγορίες MM.....	23
Εικόνα 4: Παράδειγμα απλής γραμμικής παλινδρόμησης.....	24
Εικόνα 5: Παράδειγμα δέντρου απόφασης.....	33
Εικόνα 6: Αναπαράσταση αλγορίθμου SVM με υπερεπίπεδο διαχωρισμού.....	26
Εικόνα 7: Παράδειγμα Αρχιτεκτονικής Τεχνητού Νευρωνικού Δικτύου.....	27
Εικόνα 8: Αναπαράσταση ομαδοποίησης με τον αλγόριθμο K-Means.....	29
Εικόνα 9: Παράδειγμα GMM με τρία επικαλυπτόμενα clusters.....	30
Εικόνα 10: Παράδειγμα DBSCAN clustering	31
Εικόνα 11: Παράδειγμα Spectral clustering.. ..	32
Εικόνα 12: Διάγραμμα λειτουργίας ενισχυτικής μάθησης	33
Εικόνα 13: Δομή πίνακα Q (Q-table) στο Q-learning	34
Εικόνα 14: Δομή DQN	35
Εικόνα 15: Βασική αρχιτεκτονική PPO.....	36
Εικόνα 16: Καμπύλη Elbow για τη μέθοδο K-means.....	39
Εικόνα 17: Καμπύλη Silhouette Score για τη μέθοδο K-means.....	40
Εικόνα 18: t-SNE προβολή των cluster K-means.....	42
Εικόνα 19: Καμπύλη Silhouette Score για τη μέθοδο GMM	43
Εικόνα 20: Καμπύλη κανονικοποιημένου BIC για τη μέθοδο GMM	43
Εικόνα 21: t-SNE προβολή των cluster GMM	45
Εικόνα 22: t-SNE προβολή των cluster DBSCAN	47
Εικόνα 23: t-SNE προβολή των cluster Spectral Clustering	49
Εικόνα 24: t-SNE προβολή της τυχαίας ανάθεσης προτεραιότητας.....	50
Εικόνα 25: t-SNE προβολή προτεραιότητας βάσει κανόνων	51
Εικόνα 26: Χρήση Πόρων ανά μέθοδο.....	53
Εικόνα 27: Δικαιοσύνη ανά μέθοδο	54
Εικόνα 28: Ικανοποίηση Καθυστερήσης ανά μέθοδο	54
Εικόνα 29: Αποδοτικότητα Κατανομής ανά μέθοδο	55

Λίστα Πινάκων

Πίνακας 1: Αποτελέσματα K-means για $k=2$ έως $k=10$	40
Πίνακας 2: Αποτελέσματα GMM για $k=2$ έως $k=10$	44
Πίνακας 3: Αποτελέσματα DBSCAN για διάφορους συνδυασμούς ϵ και $\min_samples$	46
Πίνακας 4: Αποτελέσματα Spectral Clustering για $k=2$ έως $k=10$	48
Πίνακας 5: Σύνοψη αποτελεσμάτων πειραμάτων	53

Συντομογραφίες

QoS	Quality of service
eMBB	Enhanced Mobile Broadband
URLLC	Ultra-Reliable Low Latency Communication
mMTC	Massive Machine Type Communications
MU-MIMO	Multi-User Multiple Input Multiple Output
MM	Μηχανική Μάθηση
DBSCAN	Density-Based Spatial Clustering of Applications with Noise
GMM	Gaussian Mixture Model
KPI	Key Performance Indicator
mmWave	Millimeter wave
IoT	Internet of Things
FDMA	Frequency Division Multiple Access
AMPS	Advanced Mobile Phone System
NMT	Nordic Mobile Telephone
TACS	Total Access Communication System
GSM	Global System for Mobile Communications
CDMA	Code Division Multiple Access
GPRS	General Packet Radio Service
UMTS	Universal Mobile Telecommunications System
HSPA	High Speed Packet Access
VoIP	Voice over Internet Protocol
LTE	Long Term Evolution
SINR	Signal-to-Interference-plus-Noise Ratio
CQI	Channel Quality Indicator
PF	Proportional Fair
RR	Round Robin
TN	Τεχνητή Νοημοσύνη
SVM	Support Vector Machine
PCA	Principal Component Analysis
DQN	Deep Q-Network
PPO	Preferred Provider Organization
V2X	Vehicle-to-Everything
WCSS	Within-Cluster Sum of Squares
t-SNE	t-distributed Stochastic Neighbor Embedding
BIC	Bayesian Information Criterion

1

Εισαγωγή

1.1 Σημασία του προβλήματος

Η ανάπτυξη των δικτύων 5G έφερε επανάσταση στις κυψελοειδείς επικοινωνίες με την εισαγωγή τεχνολογιών αιχμής, όπως ο τεμαχισμός δικτύου (Network Slicing), ο οποίος επιτρέπει τη διάσπαση ενός κοινού φυσικού δικτύου σε πολλαπλές, απολύτως διαχωρισμένες, εικονικές φέτες (slices) από άκρη σε άκρη (end-to-end). Αυτή η αρχιτεκτονική καθιστά την κατανομή πόρων πιο αποτελεσματική, εξασφαλίζοντας την κάλυψη των εξειδικευμένων απαιτήσεων ποιότητας υπηρεσιών (Quality of Service – QoS) για διαφορετικά σενάρια χρήσης, όπως η ενισχυμένη κινητή ευρυζωνικότητα (Enhanced Mobile Broadband – eMBB), οι εξαιρετικά αξιόπιστες επικοινωνίες χαμηλής καθυστέρησης (Ultra-Reliable Low Latency Communication – URLLC) και οι μαζικές επικοινωνίες τύπου μηχανής (Massive Machine Type Communications – mMTC). Ωστόσο, τα δυναμικά και τυχαία χαρακτηριστικά της κίνησης των χρηστών, οι μεταβαλλόμενες συνθήκες των καναλιών και οι ετερογενείς απαιτήσεις υπηρεσιών καθιστούν την κατανομή πόρων μια ιδιαίτερα απαιτητική πρόκληση για τα δίκτυα 5G και τα μελλοντικά συστήματα κινητών επικοινωνιών.

Διάφορες μελέτες έχουν διερευνήσει λύσεις βελτιστοποίησης για την κατανομή πόρων του δικτύου 5G. Κάποιες κατευθύνθηκαν προς τη βελτιστοποίηση των συστημάτων Multi User, Multiple Input, Multiple Output (MU-MIMO) για την αποτελεσματικότερη χρήση των πόρων μέσω του δυναμικού ελέγχου του φάσματος καθώς και της κατανομής ισχύος μεταξύ των χρηστών [1], [2]. Άλλες έρευνες έχουν στραφεί προς τον τομέα της δυναμικής κατανομής με βάση τη μηχανική μάθηση (MM), αποδεικνύοντας ότι οι λύσεις που βασίζονται σε αυτήν, αποδίδουν βελτιωμένα αποτελέσματα σε σύγκριση με τις παραδοσιακές ευρετικές μεθόδους υπό δυναμικές συνθήκες δικτύου [3], [4]. Περαιτέρω, έχουν διεξαχθεί αλγοριθμικές μελέτες κατανομής slicing δικτύου, οι οποίες αποδεικνύουν τη σημαντική βελτίωση της συνολικής απόδοσης του δικτύου μέσω της εφαρμογής έξυπνων συστημάτων κατανομής [5], [6].

Παρά τις εξελίξεις αυτές, οι παραδοσιακοί μηχανισμοί κατανομής πόρων, οι οποίοι συχνά βασίζονται σε ευρετικές μεθόδους ή κανόνες, δυσκολεύονται να προσαρμοστούν σε πραγματικό χρόνο στις διακυμάνσεις της ζήτησης κυκλοφορίας και της ποιότητας του καναλιού. Οι συμβατικές στατικές μέθοδοι κατανομής οδηγούν σε αναποτελεσματική χρήση των πόρων του δικτύου, με αποτέλεσμα την υπο-παροχή για ορισμένες φέτες και την υπερ-

παροχή για άλλες. Αυτές οι αναποτελεσματικότητες υποβαθμίζουν την απόδοση δικτύου (network efficiency), τη δικαιοσύνη (fairness) και την καθυστέρηση (latency), επηρεάζοντας τελικά την εμπειρία του τελικού χρήστη. Αν και έχουν προταθεί κάποιες τεχνικές βασισμένες στη MM για την κατανομή πόρων, οι περισσότερες μελέτες βασίζονται στην εποπτευόμενη μάθηση, η οποία απαιτεί σύνολα δεδομένων με ετικέτες, τα οποία μπορεί να μην είναι πάντα διαθέσιμα ή κλιμακούμενα σε πραγματικές εφαρμογές [7].

Η μη εποπτευόμενη μάθηση, ωστόσο, παρέχει μια πολλά υποσχόμενη λύση για την προσαρμοστική και αυτόνομη διαχείριση των πόρων σε φέτες δικτύου 5G. Με τη χρήση αλγορίθμων ομαδοποίησης (clustering), η εποπτευόμενη μάθηση μπορεί να αναγνωρίσει κρυφά μοτίβα στη συμπεριφορά των χρηστών, τις απαιτήσεις κυκλοφορίας και τις συνθήκες του δικτύου χωρίς να βασίζεται σε προκαθορισμένες ετικέτες [8]. Η παρούσα διατριβή εξηγεί πώς αλγόριθμοι μάθησης χωρίς επίβλεψη, όπως οι K-Means, Density-Based Spatial Clustering of Applications with Noise (DBSCAN), Gaussian Mixture Models (GMM) και η Φασματική Ομαδοποίηση (Spectral Clustering), μπορούν να αξιοποιηθούν για την αποτελεσματικότερη κατανομή πόρων του δικτύου εν κινήσει σε ένα πλαίσιο τεμαχισμού 5G.

1.2 Στόχοι της Εργασίας

Ο στόχος της παρούσας διπλωματικής εργασίας είναι να μελετήσει πώς οι τεχνικές μάθησης χωρίς επίβλεψη μπορούν να βελτιώσουν την κατανομή πόρων με χρήση network slicing. Η τμηματοποίηση δικτύων επιτρέπει τη διαίρεση των δικτύων 5G σε πολλαπλά εικονικά δίκτυα, καθένα από τα οποία εξυπηρετεί διαφορετικούς τύπους εφαρμογών. Η αποδοτική κατανομή πόρων είναι απαραίτητη για να διασφαλιστεί ότι αυτές οι φέτες λαμβάνουν τη σωστή ποσότητα εύρους ζώνης (bandwidth), υπολογιστικής ισχύος και άλλων πόρων δικτύου.

Οι παραδοσιακές μέθοδοι κατανομής πόρων βασίζονται συχνά σε σταθερούς κανόνες ή ευρετικές μεθόδους, οι οποίες μπορεί να μην λειτουργούν καλά όταν οι συνθήκες του δικτύου αλλάζουν. Η μη εποπτευόμενη μάθηση προσφέρει μια προσέγγιση βασισμένη σε δεδομένα που μπορεί να ομαδοποιήσει παρόμοιους χρήστες ή μοτίβα κίνησης χωρίς να χρειάζεται δεδομένα με ετικέτες. Με τη χρήση αλγορίθμων ομαδοποίησης, όπως οι K-Means, DBSCAN, GMM και Spectral Clustering, η παρούσα μελέτη στοχεύει στην εύρεση μοτίβων στη ζήτηση κίνησης και στη χρήση του δικτύου, οδηγώντας σε καλύτερη κατανομή πόρων.

Οι ειδικοί στόχοι της παρούσας διατριβής είναι:

- Να αναλύσει τις προκλήσεις της κατανομής των πόρων στο 5G network slicing και να κατανοήσει τους περιορισμούς των υφιστάμενων μεθόδων.
- Να αναπτύξει ένα μοντέλο βασισμένο στη μη εποπτευόμενη μάθηση που μπορεί να ομαδοποιήσει χρήστες ή υπηρεσίες με βάση τα χαρακτηριστικά της κίνησης του δικτύου.
- Να συγκρίνει διαφορετικές τεχνικές ομαδοποίησης (K-Means, DBSCAN, GMM και Spectral Clustering) και να προσδιορίσει την αποτελεσματικότητά τους στη βελτίωση της κατανομής πόρων.

- Να αξιολογηθεί η απόδοση της προτεινόμενης μεθόδου με τη μέτρηση βασικών παραγόντων όπως η απόδοση, το latency και το fairness σε μια προσομοίωση.
- Να συγκρίνει την προτεινόμενη μέθοδο με τις παραδοσιακές τεχνικές κατανομής πόρων και να αξιολογήσει κατά πόσο η εποπτευόμενη μάθηση παρέχει καλύτερη απόδοση.

1.3 Μεθοδολογία Προσέγγισης

Βασισμένο στα παραπάνω, οι τεχνικές μάθησης χωρίς επίβλεψη μπορούν να βελτιώσουν την κατανομή πόρων στο 5G network slicing. Η προσέγγιση περιλαμβάνει την ανάλυση μοτίβων κίνησης, την εφαρμογή αλγορίθμων ομαδοποίησης και την αξιολόγηση των επιπτώσεων στην απόδοση του δικτύου. Η μελέτη διεξάγεται με τη χρήση προσομοιώσεων και όχι με εφαρμογή σε πραγματικό χρόνο.

Αρχικά, πραγματοποιείται μια βιβλιογραφική ανασκόπηση για την κατανόηση της τεμαχισμού δικτύου 5G, των τεχνικών κατανομής πόρων και των εφαρμογών MM στις τηλεπικοινωνίες. Αυτό βοηθά στον εντοπισμό των περιορισμών των υφιστάμενων μεθόδων και στην αιτιολόγηση της χρήσης μη εποπτευόμενης μάθησης για τη δυναμική διαχείριση πόρων.

Στη συνέχεια, αναπτύσσεται ένα μοντέλο προσομοίωσης τεμαχισμού δικτύου 5G, το οποίο αναπαριστά διαφορετικά τεμάχια δικτύου με ποικίλες απαιτήσεις κίνησης. Η ρύθμιση προσομοίωσης περιλαμβάνει πολλαπλούς τύπους κυκλοφορίας, κατηγορίες χρηστών και παραμέτρους δικτύου για να αντικατοπτρίζει ρεαλιστικές συνθήκες 5G.

Για τη βελτιστοποίηση της κατανομής των πόρων, εφαρμόζονται τεχνικές μάθησης χωρίς επίβλεψη για την ανάλυση των προτύπων κίνησης και της συμπεριφοράς των χρηστών.

Εξετάζονται τέσσερεις αλγόριθμοι ομαδοποίησης:

- **K-Means** - Ένας ευρέως χρησιμοποιούμενος αλγόριθμος ομαδοποίησης που ομαδοποιεί χρήστες ή υπηρεσίες με βάση την ομοιότητα στη ζήτηση κίνησης.
- **DBSCAN** - Μια μέθοδος ομαδοποίησης με βάση την πυκνότητα που εντοπίζει μοτίβα ακόμη και σε θορυβώδη περιβάλλοντα.
- **GMM** - Ένα πιθανοτικό μοντέλο που μπορεί να συλλάβει καλύτερα τις πολύπλοκες κατανομές στα δεδομένα δικτύου.
- **Spectral Clustering** – Χρησιμοποιεί φασματική αποσύνθεση του γράφου ομοιοτήτων για να αναδείξει μη γραμμικά μοτίβα και συστάδες.

Επιπλέον, λαμβάνεται υπόψη η έννοια της προτεραιότητας (priority) μεταξύ slices, ώστε οι αλγόριθμοι ομαδοποίησης να ευνοούν τη βέλτιστη εξυπηρέτηση slices με αυστηρές

απαιτήσεις QoS. Το priority ενσωματώνεται μέσω βαρών ή ειδικής μεταχείρισης στις μετρικές αξιολόγησης της αποδοτικότητας.

Η απόδοση αυτών των τεχνικών ομαδοποίησης αξιολογείται με τη χρήση βασικών δεικτών απόδοσης δικτύου (KPIs), όπως η χρήση πόρων, το latency, το fairness και η αποδοτικότητα. Τα αποτελέσματα συγκρίνονται με παραδοσιακές μεθόδους κατανομής πόρων που βασίζονται σε ευρετικές μεθόδους για την αξιολόγηση των βελτιώσεων.

Τέλος, με βάση την αξιολόγηση, εξάγονται συμπεράσματα σχετικά με τη σκοπιμότητα της χρήσης μη εποπτευόμενης μάθησης για τη δυναμική και αποτελεσματική κατανομή πόρων σε φέτες δικτύου 5G. Η μελέτη δεν υλοποιεί ανάπτυξη σε πραγματικό χρόνο αλλά επικεντρώνεται στη θεωρητική ανάλυση και την επικύρωση βάσει προσομοίωσης.

1.4 Συνεισφορά

Η παρούσα διατριβή διερευνά τη χρήση τεχνικών μη εποπτευόμενης μάθησης για τη βελτίωση της κατανομής πόρων στο πλαίσιο του 5G network slicing, εισάγοντας μια προοπτική βασισμένη στην ομαδοποίηση προτύπων κίνησης και συμπεριφοράς χρηστών. Με τη διερεύνηση των περιορισμών των παραδοσιακών τεχνικών κατανομής, η μελέτη αυτή αποσκοπεί στην παροχή πληροφοριών σχετικά με το πώς η MM μπορεί να επιτρέψει μια πιο προσαρμοστική και έξυπνη κατανομή πόρων.

Αναπτύσσεται ένα μοντέλο προσομοίωσης για την αξιολόγηση τεσσάρων αλγορίθμων ομαδοποίησης (K-Means, DBSCAN, GMM, Spectral Clustering), με στόχο τη βελτιστοποίηση της κατανομής πόρων μεταξύ slices. Η μελέτη συγκρίνει τις επιδόσεις τους ως προς την αποδοτικότητα, το fairness και το latency, σε σχέση με συμβατικές μεθόδους. Τα ευρήματα υποδεικνύουν ότι η μη εποπτευόμενη μάθηση μπορεί να προσφέρει σημαντικά οφέλη σε δυναμικά περιβάλλοντα τηλεπικοινωνιών, ανοίγοντας τον δρόμο για πιο ευφυή και αυτοματοποιημένα δίκτυα 5G και μελλοντικών γενιών.

1.5 Διάρθρωση της Διπλωματικής Εργασίας

Η εργασία ξεκινά στο Κεφάλαιο 2 με την παρουσίαση της εξέλιξης των κυψελοειδών δικτύων από το 1G έως το 5G, με έμφαση στις βασικές τεχνολογίες που ενισχύουν τις επιδόσεις των σύγχρονων δικτύων, όπως η χρήση χιλιοστομετρικών κυμάτων (millimeter wave – mmWave), η μαζική πολλαπλή είσοδος και έξοδος (massive Multiple Input Multiple Output – massive MIMO ή mMIMO) και το network slicing.

Στο Κεφάλαιο 3 εξετάζονται παραδοσιακές τεχνικές κατανομής πόρων (Max-CQI, Proportional Fair, Max-Min Fairness, Round-Robin), μαζί με τις προκλήσεις που αντιμετωπίζουν στα σύγχρονα δίκτυα.

Το Κεφάλαιο 4 εισάγει τις βασικές κατηγορίες MM (εποπτευόμενη, μη εποπτευόμενη,

ενισχυτική) και παρουσιάζει σχετικές εφαρμογές τους στα δίκτυα 5G.

Στο Κεφάλαιο 5 περιγράφεται το περιβάλλον προσομοίωσης, το συνθετικό σύνολο δεδομένων και οι αλγόριθμοι ομαδοποίησης που εφαρμόζονται για την ανάλυση προτύπων κίνησης. Παρουσιάζονται τα πειραματικά αποτελέσματα, συγκρίνοντας την αποδοτικότητα, το fairness κατανομής και τους δείκτες latency κάθε μεθόδου.

Στο Κεφάλαιο 6 διατυπώνονται τα βασικά συμπεράσματα της εργασίας και προτείνονται προοπτικές για μελλοντική έρευνα.

Τέλος, παρατίθενται Παραρτήματα, Βιβλιογραφία και το Σύντομο Βιογραφικό του Συγγραφέα.

2

Εισαγωγή στα Δίκτυα Κινητών Επικοινωνιών και στην Τεχνολογία 5G

2.1 Εισαγωγή στα δίκτυα επικοινωνίας

Τα δίκτυα επικοινωνίας αποτελούν το θεμέλιο των σύγχρονων ψηφιακών αλληλεπιδράσεων, επιτρέποντας την απρόσκοπτη ανταλλαγή δεδομένων, φωνής και περιεχομένου πολυμέσων μεταξύ συσκευών σε όλο τον κόσμο. Τα δίκτυα αυτά υποστηρίζουν ένα ευρύ φάσμα εφαρμογών, από την περιήγηση στο διαδίκτυο και τις τηλεδιασκέψεις έως τον βιομηχανικό αυτοματισμό και τις υποδομές έξυπνων πόλεων. Στον πυρήνα τους, τα δίκτυα επικοινωνίας έχουν σχεδιαστεί για να διευκολύνουν την αποτελεσματική μεταφορά δεδομένων, εξασφαλίζοντας παράλληλα την αξιοπιστία, την ασφάλεια και την επεκτασιμότητα [9].

2.1.1 Τύποι δικτύων επικοινωνίας

Τα δίκτυα επικοινωνίας μπορούν να ταξινομηθούν σε γενικές γραμμές σε ενσύρματα και ασύρματα δίκτυα.

Ενσύρματα δίκτυα: Αυτά τα δίκτυα βασίζονται σε φυσικές συνδέσεις όπως οπτικές ίνες, ομοαξονικά καλώδια και Ethernet για τη μετάδοση δεδομένων. Τα ενσύρματα δίκτυα είναι γνωστά για τις υψηλές ταχύτητες, το χαμηλό latency και την ανθεκτική στις παρεμβολές επικοινωνία, γεγονός που τα καθιστά ιδανικά για περιβάλλοντα επιχειρήσεων, κέντρα δεδομένων και υποδομές διαδικτύου κορμού. Τα καλώδια οπτικών ινών, για παράδειγμα, προσφέρουν ταχύτητες έως και 100 Gbps και αποτελούν τη ραχοκοκαλιά των σύγχρονων υπηρεσιών διαδικτύου υψηλής ταχύτητας [10].

Ασύρματα δίκτυα: Αυτά τα δίκτυα χρησιμοποιούν ραδιοκύματα για τη μετάδοση δεδομένων, παρέχοντας κινητικότητα και ευελιξία. Τα ασύρματα δίκτυα περιλαμβάνουν Wi-Fi, δίκτυα κινητής τηλεφωνίας (3G, 4G, 5G), δορυφορικές επικοινωνίες και συστήματα που βασίζονται σε Bluetooth. Σε αντίθεση με τα ενσύρματα δίκτυα, τα ασύρματα συστήματα αντιμετωπίζουν προκλήσεις όπως παρεμβολές σήματος, τρωτά σημεία ασφαλείας και περιορισμούς στο bandwidth. Ωστόσο, οι εξελίξεις στην τεχνολογία MIMO, η διαμόρφωση

δέσμης (beamforming) και η προσαρμοστική διαμόρφωση έχουν βελτιώσει σημαντικά την απόδοση των ασύρματων δικτύων [11].

2.1.2 Βασικές λειτουργίες των δικτύων επικοινωνίας

Ανεξάρτητα από τον τύπο τους, τα δίκτυα επικοινωνίας κατασκευάζονται για να επιτελούν τις ακόλουθες λειτουργίες:

- **Μετάδοση δεδομένων:** Εξασφάλιση αποτελεσματικής παράδοσης πληροφοριών μεταξύ συσκευών μέσω πρωτοκόλλων δρομολόγησης και επιπέδων δικτύου [12].
- **Αξιοπιστία και ανοχή σφαλμάτων:** Τα δίκτυα χρησιμοποιούν ανίχνευση σφαλμάτων, πλεονασμό και εξισορρόπηση φορτίου για τη διατήρηση αδιάλειπτης υπηρεσίας.
- **Ασφάλεια και προστασία της ιδιωτικής ζωής:** Μέτρα όπως η κρυπτογράφηση, τα πρωτόκολλα ελέγχου ταυτότητας και τα τείχη προστασίας προστατεύουν τα δεδομένα από απειλές στον κυβερνοχώρο.
- **Επεκτασιμότητα και προσαρμοστικότητα:** Τα δίκτυα πρέπει να κλιμακώνονται για να εξυπηρετούν τον αυξανόμενο αριθμό χρηστών και τις εξελισσόμενες απαιτήσεις των εφαρμογών.

Με την αυξανόμενη ζήτηση για εφαρμογές πραγματικού χρόνου, υπολογιστικό νέφος και το Διαδίκτυο των πραγμάτων (IoT), τα δίκτυα επικοινωνίας έπρεπε να εξελιχθούν ώστε να υποστηρίζουν υψηλότερες ταχύτητες, χαμηλότερο latency και ενισχυμένους μηχανισμούς ασφαλείας. Αυτή η εξέλιξη οδήγησε στην ανάπτυξη των δικτύων 5G, μιας μετασχηματιστικής τεχνολογίας που βασίζεται στις προηγούμενες γενιές για να προσφέρει πρωτοφανείς δυνατότητες συνδεσιμότητας και υπηρεσιών.

2.2 Εξέλιξη των κινητών δικτύων

Η εξέλιξη των δικτύων κινητής τηλεφωνίας διαδραμάτισε καθοριστικό ρόλο στη διαμόρφωση των σύγχρονων τηλεπικοινωνιών, επιτρέποντας την απρόσκοπτη ασύρματη επικοινωνία, την πρόσβαση στο διαδίκτυο και τις υπηρεσίες πολυμέσων σε ολόκληρο τον κόσμο. Από τα πρώτα αναλογικά συστήματα της δεκαετίας του 1980 έως τα σημερινά υπερταχύτατα και χαμηλού latency δίκτυα 5G, η τεχνολογία κινητής τηλεφωνίας προσαρμόζεται συνεχώς στις απαιτήσεις των χρηστών, στις τεχνολογικές εξελίξεις και στην αυξανόμενη κίνηση δεδομένων. Κάθε γενιά έχει εισαγάγει σημαντικές βελτιώσεις στους ρυθμούς δεδομένων, την αξιοπιστία, την ασφάλεια και την αποδοτικότητα του δικτύου, διασφαλίζοντας ότι η κινητή συνδεσιμότητα παραμένει θεμελιώδες μέρος των προσωπικών, εμπορικών και βιομηχανικών εφαρμογών [13].

2.2.1 Πρώτη γενιά (1G)

Η πρώτη γενιά (1G) δικτύων κινητής τηλεφωνίας εμφανίστηκε τη δεκαετία του 1980, προσφέροντας βασική επικοινωνία φωνής μέσω αναλογικών ραδιοσημάτων. Τα συστήματα αυτά χρησιμοποιούσαν πολλαπλή πρόσβαση με διαίρεση συχνότητας (FDMA) για την κατανομή των καναλιών επικοινωνίας, αλλά υπέφεραν από κακή ποιότητα ήχου, συχνές διακοπές κλήσεων, περιορισμένη χωρητικότητα και έλλειψη ασφάλειας. Λόγω της αναλογικής φύσης της τεχνολογίας, η κρυπτογράφηση δεν ήταν δυνατή, καθιστώντας τις κλήσεις ιδιαίτερα ευάλωτες σε υποκλοπές [14].

Οι κυριότερες τεχνολογίες 1G ήταν οι εξής:

- **Προηγμένο σύστημα κινητής τηλεφωνίας (AMPS)** - χρησιμοποιείται ευρέως στις Ηνωμένες Πολιτείες.
- **Nordic Mobile Telephone (NMT)** - αναπτύχθηκε στις σκανδιναβικές χώρες.
- **Total Access Communication System (TACS)** - χρησιμοποιείται στο Ηνωμένο Βασίλειο.

Παρά τους περιορισμούς του, το 1G έθεσε τα θεμέλια για τις κινητές επικοινωνίες, ανοίγοντας το δρόμο για τη μετάβαση στα ψηφιακά δίκτυα την επόμενη δεκαετία..

2.2.2 Δεύτερη γενιά (2G)

Η εισαγωγή των δικτύων 2G στις αρχές της δεκαετίας του 1990 σηματοδότησε μια σημαντική μετάβαση από την αναλογική στην ψηφιακή επικοινωνία, βελτιώνοντας την ποιότητα των κλήσεων, την ασφάλεια και την αποτελεσματικότητα. Τα δίκτυα 2G εισήγαγαν τα μηνύματα κειμένου (SMS), τα μηνύματα πολυμέσων (MMS) και το περιορισμένο κινητό διαδίκτυο χρησιμοποιώντας υπηρεσίες δεδομένων με μεταγωγή κυκλώματος. Σε αντίθεση με το 1G, το 2G χρησιμοποίησε τεχνικές κρυπτογράφησης, καθιστώντας τις κινητές επικοινωνίες πιο ασφαλείς. Οι βασικές εξελίξεις στα δίκτυα 2G περιλάμβαναν:

- **Παγκόσμιο Σύστημα Κινητών Επικοινωνιών (GSM)** - το κυρίαρχο πρότυπο 2G, γνωστό για τη διαλειτουργικότητά του σε διάφορες περιοχές.
- **Code Division Multiple Access (CDMA)** - μια εναλλακτική λύση στο GSM με υψηλότερη φασματική απόδοση.
- **General Packet Radio Service (GPRS)** - εισήγαγε υπηρεσίες μεταγωγής πακέτων δεδομένων, υποστηρίζοντας βασική κινητή πρόσβαση στο διαδίκτυο με ταχύτητες έως 56 kbps.

Παρά τις βελτιώσεις αυτές, τα δίκτυα 2G είχαν περιορισμένες ταχύτητες μεταφοράς δεδομένων, γεγονός που οδήγησε στην ανάπτυξη των δικτύων 3G για την υποδοχή εφαρμογών πλούσιων σε πολυμέσα.

2.2.3 Τρίτη γενιά (3G)

Η τρίτη γενιά (3G) των δικτύων κινητής τηλεφωνίας, που ξεκίνησε στις αρχές της δεκαετίας του 2000, έφερε επανάσταση στις κινητές επικοινωνίες με την εισαγωγή του διαδικτύου υψηλής ταχύτητας, των εφαρμογών κινητής τηλεφωνίας και των βιντεοκλήσεων. Τα δίκτυα 3G χρησιμοποίησαν τεχνολογία μεταγωγής πακέτων, βελτιώνοντας σημαντικά τους ρυθμούς δεδομένων και την αποδοτικότητα του δικτύου.

Τα τεχνολογικά κυριότερα σημεία του 3G περιλάμβαναν:

- **Παγκόσμιο Σύστημα Κινητών Τηλεπικοινωνιών (UMTS)** - προσφέροντας μέγιστους ρυθμούς δεδομένων έως και 2 Mbps.
- **High-Speed Packet Access (HSPA)** - μια εξέλιξη του UMTS, που φτάνει σε ταχύτητες έως και 42 Mbps.
- **Υποστήριξη υπηρεσιών πολυμέσων**, συμπεριλαμβανομένης της ροής βίντεο, VoIP (Voice over IP) και κινητής ευρυζωνικότητας.

Τα δίκτυα 3G διαδραμάτισαν καθοριστικό ρόλο στην υιοθέτηση των smartphone, επιτρέποντας στους χρήστες να έχουν αποτελεσματική πρόσβαση στο διαδίκτυο και σε διαδικτυακές εφαρμογές. Ωστόσο, η συμφόρηση του δικτύου και η αυξανόμενη ζήτηση για εφαρμογές υψηλού bandwidth οδήγησαν στην εμφάνιση της τεχνολογίας 4G Long-Term Evolution (LTE).

2.2.4 Τέταρτη γενιά (4G)

Τα δίκτυα 4G (τέταρτης γενιάς), που εισήχθησαν στη δεκαετία του 2010, αντιμετώπισαν τους περιορισμούς των προηγούμενων γενιών παρέχοντας ευρυζωνική συνδεσιμότητα υψηλής ταχύτητας και χαμηλού latency. Η εισαγωγή των δικτύων LTE σηματοδότησε τη στροφή προς την αρχιτεκτονική all-IP, καθιστώντας τη μετάδοση φωνής, βίντεο και δεδομένων απρόσκοπτη και αποτελεσματική [15].

Βασικές καινοτομίες στα δίκτυα 4G:

- **LTE**- υποστήριξη μέγιστων ταχυτήτων δεδομένων έως και 1 Gbps υπό ιδανικές συνθήκες.
- **Φωνή μέσω LTE (VoLTE)** - που επιτρέπει φωνητικές κλήσεις υψηλής ευκρίνειας μέσω δικτύων IP.
- **Μαζική υιοθέτηση κινητών υπηρεσιών cloud**, παιχνιδιών σε πραγματικό χρόνο και τηλεδιασκέψεων.

Η τεχνολογία 4G βελτίωσε σημαντικά τις ευρυζωνικές επιδόσεις της κινητής τηλεφωνίας, αλλά με τον αυξανόμενο αριθμό συνδεδεμένων συσκευών και τη ζήτηση για υπηρεσίες εξαιρετικά χαμηλού latency, η ανάγκη για δίκτυα 5G έγινε εμφανής.

2.2.5 Πέμπτη γενιά και μετά (5G & beyond)

Τα δίκτυα 5G αντιπροσωπεύουν την πιο προηγμένη γενιά κινητών επικοινωνιών, σχεδιασμένα να υποστηρίζουν ένα ευρύ φάσμα εφαρμογών πέρα από τις παραδοσιακές υπηρεσίες φωνής και δεδομένων. Σε αντίθεση με τις προηγούμενες γενιές που επικεντρώθηκαν κυρίως σε υψηλότερους ρυθμούς δεδομένων, το 5G έχει σχεδιαστεί για να αντιμετωπίσει εφαρμογές ευαίσθητες στο latency, μαζική συνδεσιμότητα IoT και επικοινωνία υψηλής αξιοπιστίας [16].


Βασικά χαρακτηριστικά του 5G:

- **eMBB** - παρέχει ταχύτητες έως και 10 Gbps, επιτρέποντας καθηλωτικές εμπειρίες όπως η επαυξημένη πραγματικότητα (AR) και η εικονική πραγματικότητα (VR).
- **URLLC** - μείωση του latency σε μόλις 1 χιλιοστό του δευτερολέπτου, απαραίτητη για εφαρμογές όπως τα αυτόνομα οχήματα, ο βιομηχανικός αυτοματισμός και η τηλεϊατρική.
- **mMTC** - υποστήριξη έως και ενός εκατομμυρίου συσκευών ανά τετραγωνικό χιλιόμετρο, επιτρέποντας έξυπνες πόλεις και εφαρμογές IoT μεγάλης κλίμακας.

Η εξέλιξη των δικτύων κινητής τηλεφωνίας από το 1G στο 5G έχει μεταμορφώσει την παγκόσμια επικοινωνία, επιτρέποντας ταχύτερη μετάδοση δεδομένων, βελτιωμένη ασφάλεια και νέες υπηρεσίες. Όπως φαίνεται στην Εικόνα 1, κάθε γενιά κινητής τηλεφωνίας έχει εισαγάγει σημαντικές τεχνολογικές καινοτομίες, βελτιώνοντας τη συνδεσιμότητα και την εμπειρία των χρηστών.

The Generation Evolution

Each mobile generation brought something new to the table



Εικόνα 1: Η εξέλιξη της κυψελοειδούς επικοινωνίας [17]

Ενώ το 1G και το 2G επικεντρώθηκαν κυρίως στη φωνητική επικοινωνία, το 3G έφερε την κινητή ευρυζωνική σύνδεση, επιτρέποντας τη χρήση του διαδικτύου και των πρώτων κινητών εφαρμογών. Στη συνέχεια, το 4G LTE εισήγαγε τα δίκτυα υψηλών ταχυτήτων, διευκολύνοντας το streaming, τα κοινωνικά δίκτυα και τις cloud εφαρμογές. Σήμερα, το 5G στοχεύει να φέρει επανάσταση στις βιομηχανίες, υποστηρίζοντας αυτόνομες μεταφορές, βιομηχανικό αυτοματισμό και εφαρμογές IoT επόμενης γενιάς.

2.3 Βασικές 5G τεχνολογίες

Για την επίτευξη των αυστηρών απαιτήσεων απόδοσης, τα δίκτυα 5G ενσωματώνουν μια σειρά από προηγμένες τεχνολογίες, καθεμία από τις οποίες διαδραματίζει κρίσιμο ρόλο στην ενίσχυση της αποδοτικότητας, της αξιοπιστίας και της επεκτασιμότητας του συστήματος. Μεταξύ αυτών συγκαταλέγονται τα mmWave, η mMIMO, το beamforming, η παρυφούπολογιστική (edge computing) και το network slicing.

2.3.1 Χιλιοστομετρικά κύματα (mmWave)

Ένα από τα πιο ιδιαίτερα χαρακτηριστικά του 5G είναι η ικανότητά του να χρησιμοποιεί υψηλής συχνότητας mmWave, τα οποία κυμαίνονται από 24 GHz έως 100 GHz. Αυτές οι συχνότητες προσφέρουν υψηλότερο bandwidth, επιτρέποντας ταχύτερους ρυθμούς δεδομένων και μειωμένη συμφόρηση του δικτύου. Ωστόσο, τα σήματα mmWave έχουν μικρότερη εμβέλεια και παρεμποδίζονται εύκολα από κτίρια, δέντρα, ακόμη και από τις καιρικές συνθήκες. Για να ξεπεραστεί αυτό, απαιτείται πυκνή ανάπτυξη μικρών κυψελών και τεχνικές beamforming [18].

2.3.2 Massive MIMO (Multiple Input Multiple Output)

Η τεχνολογία mMIMO ενισχύει την αποδοτικότητα του φάσματος με τη χρήση μεγάλου αριθμού κεραιών στους σταθμούς βάσης για την ταυτόχρονη εξυπηρέτηση πολλαπλών χρηστών. Σε αντίθεση με τα παραδοσιακά συστήματα MIMO, τα οποία χρησιμοποιούν περιορισμένο αριθμό κεραιών, η mMIMO χρησιμοποιεί εκατοντάδες ή και χιλιάδες κεραίες, βελτιώνοντας σημαντικά την ποιότητα του σήματος, τη χωρητικότητα του δικτύου και τη μείωση των παρεμβολών [19].

Τα βασικά πλεονεκτήματα της mMIMO περιλαμβάνουν:

- **Υψηλότερη φασματική απόδοση**, επιτρέποντας την εξυπηρέτηση περισσότερων χρηστών με το ίδιο bandwidth.
- **Ισχυρότερη κάλυψη σήματος**, ακόμη και σε πυκνά αστικά περιβάλλοντα.
- **Βελτιωμένη διαχείριση παρεμβολών**, μειώνοντας τις διαταραχές στην ασύρματη επικοινωνία.

Παρά τα πλεονεκτήματά της, η mMIMO απαιτεί εξελιγμένους αλγορίθμους επεξεργασίας σήματος και υψηλότερη υπολογιστική ισχύ, αυξάνοντας την πολυπλοκότητα της υλοποίησης και το κόστος.

2.3.3 Διαμόρφωση Δέσμης (Beamforming)

Το Beamforming είναι μια προηγμένη τεχνική επεξεργασίας σήματος που επιτρέπει την κατευθυνόμενη μετάδοση σημάτων, αντί της εκπομπής προς όλες τις κατευθύνσεις. Με την εστίαση του ραδιοσήματος προς έναν συγκεκριμένο χρήστη ή συσκευή, το beamforming αυξάνει την αποδοτικότητα, βελτιώνει την ισχύ του σήματος και μειώνει τις παρεμβολές [20].

Το beamforming παίζει καθοριστικό ρόλο σε:

- **Επέκταση της εμβέλειας των σημάτων mmWave**, αντισταθμίζοντας τις μικρές αποστάσεις διάδοσής τους.
- **Βελτίωση της απόδοσης του δικτύου** σε περιοχές με υψηλή πυκνότητα χρηστών, όπως γήπεδα, αεροδρόμια και αστικά κέντρα.
- **Στη βελτιστοποίηση της κατανάλωσης ενέργειας**, κατευθύνοντας την ισχύ μόνο εκεί που χρειάζεται.

2.3.4 Παρυφωϋπολογιστική (Edge Computing)

Η παραδοσιακή υπολογιστική νέφους απαιτεί την επεξεργασία δεδομένων σε κεντρικά κέντρα δεδομένων, γεγονός που εισάγει latency και συμφόρηση του δικτύου. Το edge computing επιλύει αυτό το πρόβλημα με την επεξεργασία δεδομένων πιο κοντά στον χρήστη - στην άκρη του δικτύου. Αυτό μειώνει το latency και την κατανάλωση bandwidth, καθιστώντας την ιδανική για εφαρμογές πραγματικού χρόνου, όπως τα αυτόνομα οχήματα, ο βιομηχανικός αυτοματισμός και η έξυπνη επιτήρηση [21].

Πλεονεκτήματα του edge computing στο 5G:

- **Μειώνει το latency**, επιτρέποντας σχεδόν στιγμιαία επεξεργασία για εφαρμογές ευαίσθητες στον χρόνο.
- **Βελτιστοποιεί τη χρήση του bandwidth**, ελαχιστοποιώντας την ανάγκη μετάδοσης τεράστιων ποσοτήτων δεδομένων σε κεντρικούς διακομιστές.
- **Ενισχύει την ασφάλεια των δεδομένων**, καθώς οι ευαίσθητες πληροφορίες μπορούν να υποβάλλονται σε επεξεργασία τοπικά αντί να αποστέλλονται στο σύννεφο.

2.3.5 Τεμαχισμός δικτύου (Network Slicing)

Το network slicing αποτελεί μία από τις πιο θεμελιώδεις καινοτομίες του 5G, επιτρέποντας τη δημιουργία πολλαπλών λογικών (εικονικών) δικτύων πάνω στην ίδια φυσική υποδομή. Κάθε slice διαμορφώνεται ανάλογα με τις απαιτήσεις μίας συγκεκριμένης υπηρεσίας ή κατηγορίας εφαρμογών, με εγγυήσεις για bandwidth, latency, αξιοπιστία και ασφάλεια [22].

Τα slices είναι πλήρως απομονωμένα μεταξύ τους και μπορούν να αναπτυχθούν με διαφορετικές πολιτικές διαχείρισης, κάνοντας το 5G ικανό να εξυπηρετεί ταυτόχρονα πολλαπλά σενάρια χρήσης.

Ενδεικτικές περιπτώσεις χρήσης περιλαμβάνουν:

- **Βιομηχανικός Αυτοματισμός (Industry 4.0):** Ένα slice URLLC μπορεί να εξυπηρετεί εργοστασιακούς αυτοματισμούς με πολύ χαμηλό latency και υψηλή αξιοπιστία για συνεργατικά ρομπότ (cobots) και κρίσιμους ελέγχους μηχανών.
- **Έξυπνες Πόλεις (Smart Cities):** Ένα slice mMTC μπορεί να χρησιμοποιηθεί για μαζική συνδεσιμότητα αισθητήρων σε δίκτυα στάθμευσης, φωτισμού, περιβαλλοντικής παρακολούθησης ή διαχείρισης απορριμμάτων.
- **AR/VR :** Ένα slice eMBB μπορεί να διασφαλίσει υψηλό bandwidth και σταθερή ποιότητα σύνδεσης για εμπειρίες AR σε στάδια, μουσεία, τηλεεκπαίδευση ή gaming.
- **Αυτόνομη Οδήγηση και Τηλεχειρισμός Οχημάτων:** URLLC slices μπορούν να διαχειριστούν την ανταλλαγή κρίσιμων δεδομένων αισθητήρων και ελέγχου μεταξύ αυτόνομων οχημάτων και edge servers, με latency <1ms.
- **Ιδιωτικά Δίκτυα για Επιχειρήσεις (Private 5G Networks):** Πολλές εταιρείες (π.χ. λιμάνια, αεροδρόμια, εγκαταστάσεις logistics) υλοποιούν ιδιωτικά slices για να διαχειρίζονται τις δραστηριότητές τους με ασφάλεια και εγγυήσεις QoS.

Το network slicing δικτύου επιτρέπει στους παρόχους κινητής τηλεφωνίας να προσαρμόζουν τις υπηρεσίες τους σε διαφορετικούς πελάτες (π.χ. καταναλωτές, επιχειρήσεις, βιομηχανίες), διασφαλίζοντας την αποτελεσματική κατανομή των πόρων, την ποιότητα εμπειρίας (Quality of experience - QoE) και την εμπορική αξιοποίηση της υποδομής 5G σε κάθετες αγορές (verticals).

3

Τεχνικές Κατανομής Πόρων στα Δίκτυα 5G

3.1 Εισαγωγή στο πρόβλημα της κατανομής πόρων

Η κατανομή πόρων αποτελεί μία από τις βασικές προκλήσεις στα δίκτυα 5G. Σε αντίθεση με τις προηγούμενες γενιές, όπου η διαχείριση του φάσματος και του χρόνου ήταν σχετικά σταθερή, το 5G καλείται να εξυπηρετήσει ταυτόχρονα διαφορετικούς τύπους υπηρεσιών, όπως εφαρμογές μεγάλης ταχύτητας, συνδέσεις εξαιρετικά χαμηλού latency και μαζική συνδεσιμότητα μεταξύ συσκευών. Καθεμία από αυτές τις υπηρεσίες έχει διαφορετικές ανάγκες, γεγονός που καθιστά απαραίτητη μια πιο ευέλικτη και έξυπνη διαχείριση των διαθέσιμων πόρων [23].

Οι πόροι του δικτύου, όπως το φάσμα συχνοτήτων, η ισχύς μετάδοσης και ο υπολογιστικός φόρτος, δεν είναι απεριόριστοι. Πρέπει να κατανέμονται δυναμικά ανάλογα με τις απαιτήσεις των χρηστών και τις συνθήκες του περιβάλλοντος, οι οποίες μπορεί να αλλάζουν συνεχώς. Η πρόκληση είναι να διατηρείται η ποιότητα των υπηρεσιών για όλους, χωρίς να γίνεται σπατάλη πόρων ή να προκύπτουν αδικίες μεταξύ χρηστών


Για να επιτευχθεί αυτό, έχουν αναπτυχθεί διάφορες τεχνικές κατανομής πόρων, οι οποίες είτε βασίζονται σε απλούς κανόνες είτε χρησιμοποιούν πιο σύνθετες μεθόδους, όπως η MM. Οι παραδοσιακές μέθοδοι παραμένουν χρήσιμες λόγω της απλότητάς τους, αλλά συχνά δεν ανταποκρίνονται στις δυναμικές απαιτήσεις του 5G. Γι' αυτόν τον λόγο, η έρευνα επικεντρώνεται όλο και περισσότερο σε πιο προσαρμοστικές και «έξυπνες» προσεγγίσεις.

3.2 Λειτουργία Κατανομής Πόρων στα Δίκτυα 5G

Η κατανομή πόρων στα δίκτυα 5G αποτελεί μια πολυδιάστατη και χρονικά μεταβαλλόμενη διαδικασία, που πραγματοποιείται κυρίως στο επίπεδο του προγραμματιστή (scheduler) του σταθμού βάσης (Next Generation Node B - gNB). Ο scheduler (χρονοπρογραμματιστής) είναι υπεύθυνος για την απονομή ενός υποσυνόλου των διαθέσιμων πόρων του φυσικού επιπέδου – κυρίως των Resource Blocks (RBs) σε κάθε ενεργό χρήστη. Αυτή η διαδικασία λαμβάνει

χώρα περιοδικά σε κάθε Transmission Time Interval (TTI), το οποίο στο 5G NR μπορεί να είναι ευέλικτο, αλλά συνήθως ανέρχεται σε 1 ms [24].

Κάθε RB αποτελεί τη βασική μονάδα προγραμματισμού στο 5G και αντιστοιχεί σε 12 συνεχόμενους υποφορείς στο πεδίο της συχνότητας και σε ένα προκαθορισμένο αριθμό Ορθογωνικής Πολυπλεξίας Διαίρεσης Συχνότητας (Orthogonal Frequency-Division Multiplexing - OFDM) συμβόλων στον χρόνο [25]. Η συνολική διαθεσιμότητα RBs εξαρτάται από το συνολικό bandwidth που έχει διατεθεί, το subcarrier spacing (π.χ. 15–240 kHz) και την επιλεγμένη αριθμολογία του συστήματος [26]. Στην Εικόνα 2 παρουσιάζεται το πλέγμα πόρων του 5G NR. Κάθε RB αποτελείται από 12 συνεχόμενους υποφορείς στο πεδίο της συχνότητας και έναν αριθμό OFDM συμβόλων στον χρόνο, ανάλογα με την επιλεγμένη αριθμολογία (μ). Το μικρότερο στοιχείο είναι το Resource Element, που ορίζεται από ένα υποφορέα και ένα OFDM σύμβολο. Η κατανομή RBs εκτελείται από τον scheduler του σταθμού βάσης ανά TTI, συνήθως κάθε 1 ms, με στόχο την εξυπηρέτηση των ενεργών χρηστών με βάση την ποιότητα σύνδεσης και τις απαιτήσεις ποιότητας υπηρεσίας.



Εικόνα 2: Resource Grid στο 5G NR [26]

Η επιλογή των RBs για κάθε χρήστη καθορίζεται με βάση μια σειρά παραμέτρων: την ποιότητα του καναλιού, την κατηγορία υπηρεσίας, τις καθυστερήσεις πακέτων, την κατάσταση των buffers, καθώς και τις απαιτήσεις των slices στο πλαίσιο του δικτυακού τεμαχισμού. Η ανάγκη ταυτόχρονης ικανοποίησης πολλαπλών στόχων – όπως η αποδοτικότητα, το fairness και η εγγύηση QoS – προσθέτει σημαντική πολυπλοκότητα στον σχεδιασμό του scheduler [27].

Η διαδικασία κατανομής μπορεί να διαχωριστεί σε τρία βασικά βήματα: (α) την ανάκτηση της κατάστασης του καναλιού και των χρηστών, (β) την επιλογή των χρηστών που θα εξυπηρετηθούν σε κάθε TTI, και (γ) την τελική απόδοση των RBs με χρήση κάποιου αλγορίθμου βελτιστοποίησης. Ανάλογα με την πολιτική που εφαρμόζει ο scheduler, δίνεται έμφαση είτε στη μεγιστοποίηση της συνολικής ρυθμαπόδοσης, είτε στην ισότιμη εξυπηρέτηση όλων των χρηστών, είτε στην πλήρη ικανοποίηση των συμφωνιών επιπέδου υπηρεσίας (Service Level Agreements - SLAs).

Προηγμένες υλοποιήσεις scheduler εφαρμόζουν πολυκριτηριακές στρατηγικές, χρησιμοποιώντας ευρετικούς ή εξελικτικούς αλγορίθμους, όπως οι γενετικοί αλγόριθμοι (Genetic Algorithms - GA) και η βελτιστοποίηση σμήνους σωματιδίων (Particle Swarm Optimization - PSO), για την εξισορρόπηση αντικρουόμενων στόχων. Για παράδειγμα, η μελέτη των Syed Waleed et al. [28] εξετάζει την εφαρμογή του PSO για την κατανομή πόρων σε δίκτυα 5G, ενώ η μελέτη των Muhammad Saad et al. [29] προτείνει έναν υβριδικό αλγόριθμο GA-PSO για τον προγραμματισμό εργασιών σε περιβάλλοντα fog computing.

Παράλληλα, η υποστήριξη τεχνολογιών όπως το Massive MIMO και το beamforming επιβάλλει την πρόβλεψη παρεμβολών και την ταυτόχρονη εκμετάλλευση της χωρικής διαστασιοποίησης. Η ενεργειακή αποδοτικότητα αποτελεί επίσης κρίσιμο παράγοντα: ο αριθμός και η διάρκεια χρήσης των RBs επηρεάζει άμεσα τον χρόνο ενεργοποίησης των RF μονάδων και την κατανάλωση ενέργειας του σταθμού βάσης.

3.3 Παράγοντες που επηρεάζουν την κατανομή πόρων

Η κατανομή πόρων στα δίκτυα 5G είναι μια σύνθετη διαδικασία που εξαρτάται από πολλούς και διαφορετικούς παράγοντες. Αυτοί οι παράγοντες αλληλεπιδρούν μεταξύ τους και διαμορφώνουν δυναμικά τις αποφάσεις του δικτύου. Κάθε μία από τις παρακάτω παραμέτρους επηρεάζει ουσιαστικά την αποτελεσματικότητα της διαχείρισης πόρων.

Ο τύπος της υπηρεσίας είναι ένας από τους σημαντικότερους καθοριστικούς παράγοντες. Το 5G υποστηρίζει τρεις βασικές κατηγορίες εφαρμογών: eMBB, URLLC και mMTC. Κάθε κατηγορία έχει διαφορετικές απαιτήσεις: η eMBB απαιτεί υψηλή χωρητικότητα, η URLLC απαιτεί μηδενικό latency και αξιοπιστία, ενώ η mMTC απαιτεί εξυπηρέτηση μαζικών συσκευών με χαμηλή κατανάλωση πόρων. Η κατανομή πόρων οφείλει να προσαρμόζεται ανάλογα, εξισορροπώντας ταυτόχρονα την απόδοση και την ποιότητα εξυπηρέτησης.

Το **priority** αποτελεί κρίσιμο μηχανισμό στην κατανομή πόρων σε δίκτυα 5G, καθώς επιτρέπει τη βέλτιστη διαχείριση περιορισμένων πόρων, όπως το bandwidth και τα χρονικά διαστήματα μετάδοσης, ώστε να ικανοποιούνται τα διαφορετικά QoS σε συνθήκες υπερφόρτωσης. Υπηρεσίες υψηλού priority, όπως το URLLC για αυτόνομα οχήματα ή επεμβάσεις εξ αποστάσεως, λαμβάνουν προνομιακή πρόσβαση σε περισσότερους πόρους (π.χ., μεγαλύτερο φάσμα, άμεση χρονοδρομολόγηση) για να εξασφαλιστεί εξαιρετικά χαμηλό latency και υψηλή αξιοπιστία. Αντίθετα, υπηρεσίες όπως το mMTC για IoT συσκευές, που αντέχουν καθυστερήσεις, εξυπηρετούνται με χαμηλότερο priority, ενώ το eMBB για streaming υψηλής ανάλυσης απαιτεί υψηλό bandwidth. Το priority υλοποιείται μέσω βαρών στους αλγόριθμους χρονοδρομολόγησης, όπου υψηλότερα βάρη δίνουν περισσότερους

πόρους σε κρίσιμες υπηρεσίες, βελτιστοποιώντας την αποδοτικότητα του δικτύου και την εμπειρία των χρηστών, ενώ εξασφαλίζεται η τήρηση των SLAs.

Η ποιότητα του ραδιοκαναλιού αποτελεί επίσης κρίσιμο παράγοντα. Οι δείκτες SINR (Signal-to-Interference-plus-Noise Ratio) και CQI (Channel Quality Indicator) χρησιμοποιούνται από τον σταθμό βάσης για να αξιολογήσει την ποιότητα σύνδεσης κάθε χρήστη. Όσο υψηλότερος είναι ο δείκτης CQI, τόσο πιο αποδοτικά μπορεί να αξιοποιηθεί ο διαθέσιμος πόρος. Αλγόριθμοι όπως ο Maximum Channel Quality Indicator (Max-CQI) εκμεταλλεύονται αυτή την πληροφορία για να δώσουν priority στους χρήστες με καλύτερο κανάλι, κάτι που αυξάνει τη συνολική απόδοση του συστήματος αλλά μπορεί να δημιουργήσει ανισότητες [30].

Η πυκνότητα και η κινητικότητα των χρηστών επηρεάζουν σημαντικά τη στρατηγική κατανομής. Σε περιβάλλοντα υψηλής ζήτησης, όπως αεροδρόμια, στάδια ή εμπορικά κέντρα, ο αριθμός των ταυτόχρονων χρηστών είναι μεγάλος και ο ρυθμός αλλαγής των συνθηκών του καναλιού αυξάνεται. Η διαχείριση πόρων πρέπει να γίνεται με τρόπο που να εξισορροπεί τον φόρτο μεταξύ κυψελών και να αποφεύγει τη συμφόρηση. Επιπλέον, η ταχύτητα κίνησης των χρηστών (π.χ. σε τραίνα ή αυτοκίνητα) επιβάλλει μηχανισμούς που προσαρμόζονται σε συνεχώς μεταβαλλόμενες συνθήκες [31].

Η αρχιτεκτονική τεμαχισμού δικτύου εισάγει μια επιπλέον διάσταση στο πρόβλημα. Σε δίκτυα που χρησιμοποιούν slicing, κάθε slice λειτουργεί ως ένα ανεξάρτητο εικονικό δίκτυο με δικές του απαιτήσεις σε latency, ο ρυθμός μετάδοσης (throughput) και αξιοπιστία. Η κατανομή πόρων πρέπει να γίνεται ταυτόχρονα σε επίπεδο slices και σε επίπεδο χρηστών, ενώ παράλληλα να τηρούνται οι πολιτικές απομόνωσης και εγγυήσεων ποιότητας υπηρεσίας. Η πολυπλοκότητα αυξάνεται σημαντικά, καθώς οι πόροι δεν κατανέμονται πλέον μόνο σε χρήστες αλλά και σε εικονικά δίκτυα με διαφορετικές προτεραιότητες.

Οι υπολογιστικοί πόροι στην άκρη του δικτύου αποτελούν έναν νέο τύπο πόρου που πρέπει επίσης να διαχειρίζεται σωστά. Οι υπηρεσίες που απαιτούν χαμηλό latency ή μεγάλη υπολογιστική ισχύ πρέπει να εξυπηρετούνται όσο το δυνατόν πλησιέστερα στον χρήστη. Η απόφαση για το πού και πώς θα εκτελεστεί μια λειτουργία δεν αφορά μόνο τον ασύρματο σύνδεσμο, αλλά και τη διαθεσιμότητα υπολογιστικών μονάδων. Έτσι, η κατανομή πόρων επεκτείνεται πέρα από το φάσμα και την ισχύ, για να περιλάβει και το δίκτυο επεξεργασίας [32].

3.4 Παραδοσιακές τεχνικές κατανομής πόρων

Η διαχείριση των πόρων στα ασύρματα δίκτυα βασίζεται εδώ και χρόνια σε κλασικούς αλγόριθμους που προσπαθούν να εξισορροπήσουν την αποδοτικότητα με το fairness. Αυτές οι τεχνικές έχουν προσαρμοστεί και χρησιμοποιούνται ακόμα στα δίκτυα 5G, είτε ως βασικά εργαλεία είτε ως σημεία αναφοράς.

Ο αλγόριθμος **Max-CQI** εκμεταλλεύεται την πληροφορία για την ποιότητα του καναλιού, επιλέγοντας κάθε φορά τον χρήστη με CQI. Με αυτόν τον τρόπο, βελτιστοποιείται η απόδοση του συστήματος, καθώς οι πόροι δίνονται σε χρήστες με καλύτερη σύνδεση [33].

Ο αλγόριθμος **Proportional Fair (PF)** επιχειρεί να εξισορροπήσει την αποδοτικότητα με τη δίκαιη κατανομή πόρων. Βασίζεται στον λόγο μεταξύ του άμεσου throughput ενός χρήστη και του μέσου ρυθμού που είχε στο παρελθόν, επιτρέποντας το priority στους χρήστες που δεν έχουν εξυπηρετηθεί επαρκώς [34].

Η προσέγγιση **Max-Min Fairness** δίνει priority στον χρήστη με τη χαμηλότερη ρυθμιαπόδοση, προσπαθώντας να μεγιστοποιήσει το ελάχιστο που λαμβάνει οποιοσδήποτε χρήστης στο σύστημα. Αυτή η τεχνική εξασφαλίζει βασική ποιότητα υπηρεσίας για όλους, ακόμη και αν αυτό γίνεται εις βάρος της συνολικής απόδοσης [35].

Η μέθοδος **Round Robin (RR)** κατανέμει τους πόρους διαδοχικά σε όλους τους χρήστες, χωρίς να λαμβάνει υπόψη την κατάσταση του καναλιού ή τις ανάγκες των εφαρμογών. Ενώ είναι εύκολη στην υλοποίηση και δίκαιη ως προς τον χρόνο εξυπηρέτησης, δεν επιτυγχάνει καλή χρήση των πόρων σε ετερογενή δίκτυα [36].

Η μέθοδος **Random Assignment** πραγματοποιεί την κατανομή πόρων με τυχαίο τρόπο, αποδίδοντας τους διαθέσιμους πόρους στους χρήστες χωρίς να λαμβάνει υπόψη την κατάσταση του καναλιού, τις απαιτήσεις υπηρεσιών ή το priority των slices. Παρότι αυτή η προσέγγιση στερείται κάθε μορφής βελτιστοποίησης, χρησιμοποιείται ευρέως ως baseline μέθοδος σε συγκριτικές μελέτες, προκειμένου να αξιολογηθεί η απόδοση πιο εξελιγμένων αλγορίθμων. Το κύριο πλεονέκτημά της είναι η ευκολία υλοποίησης, ενώ το βασικό της μειονέκτημα είναι η χαμηλή αποδοτικότητα και η απουσία εγγυήσεων για QoS ή fairness.

Η προσέγγιση **Rule-Based Allocation** βασίζεται σε στατικούς, προκαθορισμένους κανόνες για την απόδοση πόρων. Τέτοιοι κανόνες μπορεί να είναι η εξυπηρέτηση κατά σειρά άφιξης (first-come-first-served), η ανάθεση με βάση προκαθορισμένα thresholds χρηστών ή slices, ή ακόμα και η χειροκίνητη ιεράρχηση. Αυτές οι μέθοδοι ενσωματώνουν την εμπειρία του σχεδιαστή δικτύου, είναι εύκολα παραμετροποιήσιμες και εφαρμόζονται σε πρακτικά συστήματα χαμηλής πολυπλοκότητας. Ωστόσο, αποτυγχάνουν να προσαρμοστούν σε δυναμικές συνθήκες ή σε περιβάλλοντα υψηλής μεταβλητότητας, με αποτέλεσμα να υπολείπονται σε αποδοτικότητα συγκριτικά με αλγορίθμους που βασίζονται σε δεδομένα.

3.5 Κατανομή Πόρων υπό Συνθήκες Παρεμβολών και Ετερογένειας

Στα δίκτυα 5G, η αποτελεσματική κατανομή ραδιοπόρων επηρεάζεται καθοριστικά από τις παρεμβολές, τόσο τις ενδο-κυψελικές (εντός της ίδιας κυψέλης) όσο και τις δια-κυψελικές (μεταξύ γειτονικών κυψελών). Οι παρεμβολές αυτές μπορούν να υποβαθμίσουν σημαντικά την απόδοση του συστήματος – μειώνοντας το throughput, την αξιοπιστία και το fairness στην κατανομή πόρων – αν δεν αντιμετωπιστούν κατάλληλα. Ιδιαίτερα σε μια ετερογενή, πολυεπίπεδη αρχιτεκτονική 5G με μακροκυψέλες, μικροκυψέλες και επικοινωνίες συσκευή-προς-συσκευή, η διαχείριση παρεμβολών αναδεικνύεται σε μία από τις σοβαρότερες προκλήσεις για την κατανομή πόρων. [37]

Οι ενδο-κυψελικές παρεμβολές περιορίζονται συνήθως μέσω ορθογώνιας πολλαπλής πρόσβασης. Εντούτοις, σε περιπτώσεις όπου εφαρμόζονται μη ορθογώνιες τεχνικές πρόσβασης ή ταυτόχρονες μεταδόσεις (όπως στο NOMA ή σε πυκνή ταυτόχρονη κίνηση στο ανερχόμενο κανάλι), μπορεί να προκύψουν παρεμβολές εντός της κυψέλης που απαιτούν έξυπνο προγραμματισμό ώστε να αποφευχθεί η επικάλυψη παρόμοιων πόρων. Από την άλλη πλευρά, οι δια-κυψελικές παρεμβολές αποτελούν μείζονα πρόκληση στα κυψελωτά δίκτυα. Όταν γειτονικές κυψέλες κάνουν χρήση του ίδιου φάσματος χωρίς συντονισμό, τα σήματά τους αλληλοπαρεμβάλλονται ιδιαίτερα στις ζώνες επικάλυψης (στα όρια των κυψελών), μειώνοντας το SINR των χρηστών εκεί. Στα ετερογενή δίκτυα 5G, όπου μακροκυψέλες και πυκνά αναπτυγμένες μικρο/φεμτοκυψέλες συνυπάρχουν στο ίδιο φάσμα, εμφανίζεται έντονη δια-στρωματική παρεμβολή (cross-tier interference) μεταξύ των κυψελών διαφορετικού μεγέθους [38]. Αυτό μπορεί να οδηγήσει σε σημαντική μείωση του throughput των χρηστών στις μικρότερες κυψέλες και γενικά υποβάθμιση της απόδοσης, εάν δεν εφαρμοστούν μηχανισμοί συντονισμού κατά την κατανομή των πόρων.

Για την αντιμετώπιση των παρεμβολών, το 5G ενσωματώνει προχωρημένες τεχνικές χρονοπρογραμματισμού που λαμβάνουν υπόψη το επίπεδο παρεμβολής (interference-aware scheduling) και μηχανισμούς συντονισμού μεταξύ σταθμών βάσης. Μια χαρακτηριστική προσέγγιση είναι η τεχνική Coordinated Multipoint (CoMP) – Συντονισμένη Μετάδοση από Πολλαπλά Σημεία – όπου πολλοί gNBs συνεργάζονται για την εξυπηρέτηση των χρηστών στις άκρες των κυψελών. Μέσω του CoMP, οι σταθμοί βάσης είτε προγραμματίζουν συντονισμένα τους πόρους τους ώστε να αποφεύγεται η αμοιβαία παρεμβολή, είτε πραγματοποιούν κοινή μετάδοση (joint transmission) προς έναν χρήστη από πολλαπλές κεραιές/κυψέλες ταυτόχρονα. Αυτό έχει ως αποτέλεσμα τη μείωση της δια-κυψελικής παρεμβολής και τη βελτίωση της κάλυψης και των ρυθμών δεδομένων για τους χρήστες στα όρια των κυψελών [39]. Βεβαίως, το κόστος συντονισμού αυξάνεται με αυτές τις τεχνικές, όμως θεωρείται αναγκαίο τίμημα για την επίτευξη υψηλότερης φασματικής αποδοτικότητας και αξιοπιστίας στις συνθήκες έντονων παρεμβολών.

Τέλος, η ετερογένεια του εξοπλισμού χρήστη και των εφαρμογών στο 5G απαιτεί την προσαρμογή των αλγορίθμων κατανομής πόρων ώστε να ικανοποιούν ποικίλες απαιτήσεις, ελαχιστοποιώντας παράλληλα τις παρεμβολές. Τα δίκτυα 5G εξυπηρετούν μια μεγάλη γκάμα τερματικών συσκευών – από έξυπνα τηλέφωνα που απαιτούν ευρυζωνικές ταχύτητες (εφαρμογές eMBB), μέχρι αισθητήρες IoT χαμηλής ισχύος που μεταδίδουν αραιά μικρούς όγκους δεδομένων. Η συνεπάρξή τους στο ίδιο δίκτυο συνεπάγεται ότι ο προγραμματισμός των πόρων πρέπει να είναι αρκετά ευέλικτος. Για παράδειγμα, το 5G εισάγει την έννοια των πολλαπλών αριθμολογιών στο φυσικό επίπεδο – διαφορετικές υποφερουσες αποστάσεις (subcarrier spacing) και διάρκειες συμβόλου για διαφορετικές κατηγορίες υπηρεσιών – ώστε να εξυπηρετούνται αποδοτικά τόσο οι συσκευές υψηλών απαιτήσεων όσο και οι συσκευές χαμηλής ισχύος. Ωστόσο, η παράλληλη χρήση διαφορετικών αριθμολογιών μπορεί να επιφέρει παρεμβολές μεταξύ των σημάτων (φαινόμενο inter-numerology interference), οι οποίες υποβαθμίζουν κυρίως τις ευαίσθητες επικοινωνίες mMTC αν δεν προβλεφθούν προστατευτικές ζώνες ή κατάλληλα φίλτρα [40].

Επομένως, οι αλγόριθμοι κατανομής πόρων στο 5G οφείλουν να προσαρμόζονται στην ετερογένεια τόσο των δικτυακών στοιχείων όσο και των τερματικών: να λαμβάνουν υπόψη τις διαφορετικές ικανότητες και ανάγκες των συσκευών (π.χ. priority σε αξιόπιστη και χαμηλού latency μετάδοση για ένα IoT αισθητήρα έναντι υψηλού throughput για ένα

smartphone), καθώς και να συντονίζουν την κατανομή σε πολλαπλές στρώσεις κυψελών. Μέσω κατάλληλου σχεδιασμού (π.χ. με διαχωρισμό πόρων ανά κατηγορία υπηρεσίας ή network slicing), το σύστημα μπορεί να αποφύγει βλαβερές παρεμβολές μεταξύ ετερογενών συσκευών και παράλληλα να αξιοποιήσει αποδοτικά το φάσμα, προσφέροντας την απαιτούμενη QoS σε κάθε περίπτωση.

3.6 Παραδοσιακές Προσεγγίσεις Κατανομής Πόρων σε Περιβάλλον Sliced Δικτύων 5G

Η κατανομή πόρων σε περιβάλλοντα δικτυακής τεμαχισμού (network slicing) αποτελεί κρίσιμο παράγοντα για την επίτευξη του QoS σε δίκτυα 5G. Παραδοσιακές προσεγγίσεις βασίζονται σε κανόνες (rule-based) και ευρετικούς αλγορίθμους για τη διαχείριση των πόρων μεταξύ των slices.

Μία τέτοια προσέγγιση παρουσιάζεται από τους FAHIM et al. (2023), όπου προτείνεται ένα πλαίσιο κατανομής πόρων που λαμβάνει υπόψη το latency και το priority κάθε slice. Το priority καθορίζεται από το βάρος κάθε slice και τις απαιτήσεις QoS, επιτρέποντας την αποδοτική χρήση των διαθέσιμων ραδιοφωνικών πόρων. Το προτεινόμενο πλαίσιο διασφαλίζει ότι κάθε slice μπορεί να μοιραστεί τα ανώτατα επιτρεπτά όρια πόρων για την επίτευξη της ελάχιστου επιτρεπτού latency, ένα από τα πιο σημαντικά χαρακτηριστικά στα δίκτυα 5G. [41]

Άλλες προσεγγίσεις περιλαμβάνουν τη χρήση ευρετικών αλγορίθμων, όπως οι MCRA και FLDR, που στοχεύουν στη δυναμική δρομολόγηση και κατανομή πόρων για slices πολλαπλών ενοικιαστών σε αρχιτεκτονική δύο επιπέδων. Οι αλγόριθμοι αυτοί λαμβάνουν υπόψη τη χρήση πόρων σε πραγματικό χρόνο και τις απαιτήσεις latency, επιτρέποντας την αποδοτική κατανομή πόρων και την ελαχιστοποίηση του latency. [42]

Επιπλέον, προσεγγίσεις βασισμένες σε οικονομικά μοντέλα, όπως ο μηχανισμός Kelly, έχουν προταθεί για την κατανομή πόρων σε περιβάλλοντα network slicing. Αυτές οι μέθοδοι επιτρέπουν την κατανομή πόρων με βάση τη ζήτηση και τις προσφορές των slices, διασφαλίζοντας την αποδοτική χρήση των διαθέσιμων πόρων. [43]

Συνοψίζοντας, οι παραδοσιακές προσεγγίσεις κατανομής πόρων σε περιβάλλοντα network slicing βασίζονται σε κανόνες και ευρετικούς αλγορίθμους που λαμβάνουν υπόψη τις απαιτήσεις QoS, το latency και τη χρήση πόρων σε πραγματικό χρόνο. Αν και αυτές οι μέθοδοι έχουν αποδειχθεί αποτελεσματικές σε ορισμένα σενάρια, η αυξανόμενη πολυπλοκότητα και οι δυναμικές απαιτήσεις των δικτύων 5G καθιστούν αναγκαία την εξέλιξη προς πιο ευέλικτες και ευφυείς τεχνικές κατανομής πόρων.

3.7 Η Ανάγκη για Ευφυείς Τεχνικές Κατανομής

Οι παραδοσιακές τεχνικές κατανομής πόρων, παρότι αποτελεσματικές σε στατικές ή απλοποιημένες συνθήκες, δεν μπορούν να ανταποκριθούν επαρκώς στην πολυπλοκότητα και

τη δυναμικότητα των σύγχρονων 5G δικτύων. Η ταχεία εναλλαγή της κυκλοφορίας, οι διαφοροποιημένες απαιτήσεις υπηρεσιών και η ύπαρξη πολλών slices καθιστούν αναγκαία την υιοθέτηση ευφυών, προσαρμοστικών μεθόδων.

Η MM και ιδιαίτερα η μη εποπτευόμενη μάθηση (Unsupervised Learning), παρέχουν τη δυνατότητα στους αλγόριθμους να ανακαλύπτουν μοτίβα στη χρήση των πόρων και να προσαρμόζουν τις αποφάσεις κατανομής χωρίς να απαιτείται ρητή μοντελοποίηση όλων των παραμέτρων του συστήματος.

Τεχνικές όπως η ομαδοποίηση, η ενισχυτική μάθηση (reinforcement learning), και οι νευρωνικές αρχιτεκτονικές προσφέρουν προσαρμοστικότητα και δυνατότητα πρόβλεψης μελλοντικών συνθηκών. Το επόμενο κεφάλαιο εξετάζει αναλυτικά τις αρχές της MM και τις εφαρμογές της στην κατανομή πόρων στα 5G δίκτυα.

4

Εισαγωγή στη Μηχανική Μάθηση και τις Εφαρμογές της στα Δίκτυα 5G


4.1 Τι είναι η Μηχανική Μάθηση (MM)

Η MM αποτελεί έναν από τους πλέον σημαντικούς και ταχέως αναπτυσσόμενους τομείς της τεχνητής νοημοσύνης (TN). Στόχος της είναι να αναπτύξει υπολογιστικά συστήματα ικανά να μαθαίνουν από δεδομένα και να βελτιώνουν τη συμπεριφορά τους με την πάροδο του χρόνου, χωρίς να απαιτείται ρητός προγραμματισμός από τον άνθρωπο

Η βασική αρχή πίσω από τη MM είναι η ανακάλυψη προτύπων, σχέσεων και συσχετίσεων μέσα σε μεγάλους όγκους δεδομένων, με στόχο τη λήψη αποφάσεων, την πρόβλεψη ή την κατηγοριοποίηση νέων δεδομένων. Στο πλαίσιο των δικτύων 5G, οι τεχνολογίες MM χρησιμοποιούνται για την πρόβλεψη της κίνησης, τη διαχείριση του φάσματος, την κατανομή πόρων και την αυτόματη προσαρμογή των παραμέτρων λειτουργίας του δικτύου.

Οι κύριες κατηγορίες MM είναι: η εποπτευόμενη μάθηση (supervised learning), η μη εποπτευόμενη μάθηση (unsupervised learning) και η ενισχυτική μάθηση (reinforcement learning). Η κάθε κατηγορία εξυπηρετεί διαφορετικούς σκοπούς και εφαρμόζεται σε διαφορετικά προβλήματα, ανάλογα με τη διαθεσιμότητα δεδομένων, τον στόχο της ανάλυσης και τη δυναμική του περιβάλλοντος [44].

Ένας από τους πιο βασικούς δομικούς λίθους σε πολλές τεχνικές MM είναι τα τεχνητά νευρωνικά δίκτυα, τα οποία μιμούνται τη λειτουργία του ανθρώπινου εγκεφάλου και επιτρέπουν την αναγνώριση πολύπλοκων προτύπων σε δεδομένα. Η Εικόνα 3 παρουσιάζει συνοπτικά τις βασικές κατηγορίες της MM.



Εικόνα 3: Βασικές Κατηγορίες ΜΜ

4.2 Εποπτευόμενη Μάθηση (Supervised Learning)

Η εποπτευόμενη μάθηση βασίζεται σε δεδομένα τα οποία περιλαμβάνουν τόσο τις εισόδους όσο και τις αντίστοιχες επιθυμητές εξόδους, γνωστές ως «ετικέτες». Ο αλγόριθμος μαθαίνει να προβλέπει τη σωστή έξοδο για κάθε νέα είσοδο με βάση την εμπειρία από τα εκπαιδευτικά δεδομένα. Οι πιο κοινές εφαρμογές περιλαμβάνουν την κατηγοριοποίηση (classification) και την παλινδρόμηση (regression) [45].

4.2.1 Γραμμική Παλινδρόμηση (Linear Regression)

Η γραμμική παλινδρόμηση είναι από τις πιο βασικές και κατανοητές τεχνικές της εποπτευόμενης μάθησης. Ο βασικός της στόχος είναι να βρει μια μαθηματική σχέση ανάμεσα σε μία ή περισσότερες μεταβλητές εισόδου (γνωστές και ως χαρακτηριστικά) και σε μία μεταβλητή εξόδου (γνωστή ως στόχος ή ετικέτα). Αυτή η σχέση περιγράφεται με τη μορφή μιας ευθείας γραμμής, η οποία προσαρμόζεται στα δεδομένα ώστε να «ταιριάζει» όσο το δυνατόν καλύτερα στις τιμές που έχουμε παρατηρήσει.


Πρακτικά, το μοντέλο προσπαθεί να υπολογίσει τους βέλτιστους συντελεστές (slopes) της ευθείας, ώστε η απόσταση ανάμεσα στις προβλέψεις του μοντέλου και τις πραγματικές τιμές να είναι όσο το δυνατόν μικρότερη. Αυτό επιτυγχάνεται με τη χρήση κάποιας συνάρτησης κόστους, συνήθως το μέσο τετράγωνο σφάλμα (Mean Squared Error - MSE), το οποίο μετρά τη μέση απόκλιση των προβλέψεων από τις πραγματικές τιμές.

Η απλή γραμμική παλινδρόμηση (simple linear regression) αφορά την περίπτωση όπου υπάρχει μόνο μία μεταβλητή εισόδου. Η πολλαπλή γραμμική παλινδρόμηση (multiple linear regression) επεκτείνει αυτή την ιδέα σε πολλές μεταβλητές εισόδου. Η βασική μαθηματική μορφή για το μοντέλο είναι:

$$\hat{y} = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n$$

όπου: $\hat{y}$ είναι η προβλεπόμενη έξοδος, x_i είναι τα χαρακτηριστικά εισόδου, w_i είναι οι αντίστοιχοι συντελεστές (βάρη), w_0 είναι η σταθερά ή το «bias». Η εκπαίδευση του μοντέλου σημαίνει την εύρεση των βαρών w_i που ελαχιστοποιούν το σφάλμα στις προβλέψεις.

Στα δίκτυα 5G, η γραμμική παλινδρόμηση μπορεί να εφαρμοστεί για την πρόβλεψη κρίσιμων μεγεθών, όπως throughput, latency ή QoS, βασιζόμενη σε μετρήσιμες παραμέτρους όπως η ένταση του σήματος (RSRP), ο αριθμός ενεργών χρηστών σε μία κυψέλη ή ο διαθέσιμος φασματικός πόρος. Χάρη στην απλότητά της, η γραμμική παλινδρόμηση χρησιμοποιείται συχνά ως baseline μοντέλο για σύγκριση με πιο πολύπλοκες μεθόδους [46].



Εικόνα 4: Παράδειγμα απλής γραμμικής παλινδρόμησης

4.2.2 Δέντρα Απόφασης και Τυχαία Δάση

Τα δέντρα απόφασης είναι ένας από τους πιο ευέλικτους και ευκολονόητους αλγόριθμους εποπτευόμενης μάθησης. Η βασική τους λειτουργία μοιάζει με μία σειρά από «ερωτήσεις» που οδηγούν σε μια τελική απόφαση. Απεικονίζονται με μορφή δέντρου, όπου κάθε εσωτερικός κόμβος (node) αντιστοιχεί σε έναν έλεγχο (π.χ., «αν η ισχύς σήματος είναι μεγαλύτερη από X »), και τα φύλλα (leaves) αντιστοιχούν σε την τελική πρόβλεψη (π.χ., «τύπος υπηρεσίας = video»).


Ο αλγόριθμος μαθαίνει ποια χαρακτηριστικά είναι τα πιο χρήσιμα για τον διαχωρισμό των δεδομένων σε κατηγορίες ή για την πρόβλεψη μιας τιμής. Η διαδικασία δημιουργίας του δέντρου ονομάζεται "κατάτμηση" (splitting), και βασίζεται σε κριτήρια όπως η μείωση της εντροπίας (entropy) ή του σφάλματος. Το δέντρο συνεχίζει να αναπτύσσεται μέχρι τα δεδομένα να διαχωριστούν πλήρως ή να φτάσουμε σε έναν προκαθορισμένο περιορισμό (π.χ., μέγιστο βάθος).

Ωστόσο, τα μεμονωμένα δέντρα έχουν το πρόβλημα της υπερπροσαρμογής (overfitting), δηλαδή αποτυπώνουν υπερβολικά καλά τα δεδομένα εκπαίδευσης και δεν γενικεύουν καλά

σε νέα δεδομένα. Για να λυθεί αυτό το πρόβλημα, χρησιμοποιείται η τεχνική των Τυχαίων Δασών (Random Forests).

Τα Random Forests δημιουργούν πολλά διαφορετικά δέντρα, καθένα από τα οποία εκπαιδεύεται με τυχαίο υποσύνολο των δεδομένων και των χαρακτηριστικών (τεχνική bootstrap). Κατά την πρόβλεψη, η τελική απόφαση λαμβάνεται με classification ή regression των αποφάσεων όλων των δέντρων. Αυτός ο μηχανισμός μειώνει σημαντικά την πιθανότητα overfitting, διατηρώντας παράλληλα υψηλή ακρίβεια [47].

Στα δίκτυα 5G, τα δέντρα απόφασης και τα τυχαία δάση έχουν εφαρμοστεί: για την ταξινόμηση της χρήσης συσκευών (αν πρόκειται για video streaming, IoT αισθητήρες, ή εφαρμογές με χαμηλό latency) [48], για την πρόβλεψη της φόρτωσης κυκλοφορίας (traffic load) σε συγκεκριμένες κυψέλες, για την εκτίμηση πιθανότητας αποτυχίας handover ή συμφοράς σε slices [49].



Εικόνα 5: Παράδειγμα δέντρου απόφασης


4.2.3 Support Vector Machines (SVM)

Οι μηχανές υποστηρικτικών διανυσμάτων (Support Vector Machines – SVM) αποτελούν μία ισχυρή τεχνική εποπτευόμενης μάθησης για προβλήματα κατηγοριοποίησης και παλινδρόμησης. Η βασική αρχή λειτουργίας ενός SVM είναι η εύρεση της υπερεπιφάνειας (hyperplane) που διαχωρίζει καλύτερα τα δεδομένα σε δύο (ή περισσότερες) κατηγορίες, μεγιστοποιώντας το περιθώριο μεταξύ των πιο κοντινών σημείων κάθε κατηγορίας (support vectors). Σε απλή γραμμικά διαχωρίσιμη περίπτωση, ο αλγόριθμος επιδιώκει την κατασκευή ενός γραμμικού υπερεπιπέδου που να ικανοποιεί:

$$\mathbf{w} \cdot \mathbf{x}_i + \mathbf{b} \geq 1 \quad \text{για } y_i = +1 \quad \& \quad \mathbf{w} \cdot \mathbf{x}_i + \mathbf{b} \leq -1 \quad \text{για } y_i = -1$$

Όπου $\mathbf{w}$ είναι το διάνυσμα βαρών, $\mathbf{b}$ είναι ο όρος μετατόπισης (bias), και $y_i \in \{-1, +1\}$ είναι η ετικέτα του δείγματος. Για πιο πολύπλοκα δεδομένα που δεν είναι γραμμικά διαχωρίσιμα, οι

SVM χρησιμοποιούν τεχνικές πυρήνα (kernel methods), οι οποίες μετασχηματίζουν το σύνολο δεδομένων σε μεγαλύτερης διάστασης χώρο όπου είναι δυνατός ο διαχωρισμός. Κοινοί πυρήνες είναι ο γραμμικός, ο πολυωνυμικός και ο RBF (Radial Basis Function). Οι SVM βρίσκουν εφαρμογή σε πολλά υποσυστήματα του 5G. Για παράδειγμα χρησιμοποιούνται στην ανίχνευση παρεμβολών και επιθέσεων (Intrusion/Interference Detection) εκπαιδεύοντας τα σε κανονικά και ανώμαλα δείγματα ώστε να αναγνωρίζουν κακόβουλη συμπεριφορά ή επιδείνωση της ποιότητας σύνδεσης. Επίσης μπορούν να χρησιμοποιηθούν στην ταξινόμηση χρηστών ή συσκευών, στην κατηγοριοποίηση χρηστών σε κατηγορίες QoS (π.χ., απαιτήσεις latency ή throughput), αλλά και στην απόφαση handover σε περιβάλλοντα με μεγάλη κινητικότητα, προβλέποντας πότε και προς ποιον σταθμό βάσης πρέπει να πραγματοποιηθεί η αλλαγή σύνδεσης. Μια σχετική μελέτη παρουσιάζει την ανίχνευση επιθέσεων παρεμβολής σε δίκτυα 5G C-RAN χρησιμοποιώντας συνδυασμό βαθιάς μάθησης και SVM, επιτυγχάνοντας ακρίβεια ταξινόμησης 94,51% και ποσοστό ψευδών αρνητικών 7,84% [50]. Η Εικόνα 6 απεικονίζει ένα παράδειγμα ομαδοποίησης με χρήση SVM.



Εικόνα 6: Αναπαράσταση αλγορίθμου SVM με υπερεπίπεδο διαχωρισμού


4.2.4 Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks)

Τα τεχνητά νευρωνικά δίκτυα αποτελούν ένα από τα πιο δυναμικά και διαδεδομένα εργαλεία της εποπτευόμενης ΜΜ, εμπνευσμένα από τη λειτουργία του ανθρώπινου εγκεφάλου. Η βασική τους αρχή έγκειται στην ύπαρξη διαδοχικών επιπέδων υπολογιστικών κόμβων (νευρώνων), οι οποίοι λαμβάνουν σήματα από προηγούμενα επίπεδα, τα επεξεργάζονται μέσω μαθηματικών συναρτήσεων και μεταδίδουν τα αποτελέσματα στα επόμενα. Κάθε νευρώνας εφαρμόζει πρώτα έναν γραμμικό μετασχηματισμό των εισερχόμενων δεδομένων

και στη συνέχεια περνά το αποτέλεσμα από μία μη γραμμική συνάρτηση ενεργοποίησης, όπως η ReLU ή η sigmoid, ώστε να είναι δυνατή η εκμάθηση πολύπλοκων συσχετίσεων. Η εκπαίδευση του δικτύου επιτυγχάνεται με τη διαδικασία της προώθησης (forward propagation) και της οπισθοδιάδοσης (backpropagation), κατά την οποία το σφάλμα της πρόβλεψης διαχέεται πίσω στο δίκτυο και τα βάρη των συνδέσεων προσαρμόζονται, ώστε να ελαχιστοποιηθεί η συνάρτηση απώλειας.

Η ισχύς των νευρωνικών δικτύων έγκειται στην ικανότητά τους να μοντελοποιούν πολύπλοκα, μη γραμμικά φαινόμενα, γεγονός που τα καθιστά ιδανικά για τις απαιτήσεις των 5G δικτύων. Στο συγκεκριμένο πλαίσιο, τα ANN έχουν αξιοποιηθεί ευρέως για την πρόβλεψη του QoE, την αναγνώριση μοτίβων στην κίνηση του δικτύου, καθώς και για την κατανομή φασματικών πόρων με τρόπο που μεγιστοποιεί την αποδοτικότητα και την εξυπηρέτηση. Ειδικότερα, μπορούν να εντοπίσουν διακυμάνσεις στο φορτίο κυκλοφορίας και να προβλέψουν αιχμές, βελτιώνοντας τη διαχείριση των handovers και τη συνολική ποιότητα παροχής υπηρεσιών. Χάρη στην ευελιξία τους, τα ANN προσαρμόζονται εύκολα σε πολύπλοκες εισόδους, όπως η χωρική κατανομή χρηστών, οι δυναμικές συνθήκες καναλιού και οι πολλαπλές QoS απαιτήσεις των slices.

Παρά τη μεγάλη τους ισχύ, ωστόσο, τα νευρωνικά δίκτυα συνοδεύονται από ορισμένες προκλήσεις, όπως η ανάγκη για μεγάλα σύνολα δεδομένων εκπαίδευσης και η δυσκολία ερμηνείας των εσωτερικών τους αποφάσεων, γεγονός που περιορίζει τη διαφάνεια και την αξιοπιστία τους σε κρίσιμα περιβάλλοντα. Παρ' όλα αυτά, η συνεχής πρόοδος στον σχεδιασμό πιο ελαφριών, αποδοτικών και κατανοητών αρχιτεκτονικών (όπως τα lightweight CNNs ή τα attention-based networks) ενισχύει τη χρήση των ANN στα 5G συστήματα, μετατρέποντάς τα σε βασικό πυλώνα της αυτοματοποιημένης, έξυπνης διαχείρισης του δικτύου. Μια σχετική μελέτη προτείνει ένα πλαίσιο βασισμένο σε βαθιά μάθηση για την κατανομή ραδιοφωνικών πόρων σε δίκτυα 5G, το οποίο χρησιμοποιεί διαδοχικά νευρωνικά δίκτυα για την ελαχιστοποίηση της κατανάλωσης ισχύος, διατηρώντας ταυτόχρονα τις απαιτήσεις QoS [51].



Εικόνα 7: Παράδειγμα Αρχιτεκτονικής Τεχνητού Νευρωνικού Δικτύου

4.3 Μη Εποπτευόμενη Μάθηση (*Unsupervised Learning*)

Η μη εποπτευόμενη μάθηση αποτελεί έναν θεμελιώδη κλάδο της ΜΜ και αφορά περιπτώσεις όπου τα δεδομένα δεν περιέχουν προκαθορισμένες ετικέτες ή επιθυμητές εξόδους. Ο στόχος είναι η ανακάλυψη εσωτερικών δομών, προτύπων ή σχέσεων μέσα στα δεδομένα, χωρίς να έχει προηγηθεί κάποια καθοδήγηση. Οι αλγόριθμοι αυτής της κατηγορίας είναι ιδιαίτερα χρήσιμοι για την κατανόηση του υποκείμενου σχήματος των δεδομένων, την ομαδοποίηση, τη μείωση διαστατικότητας και την ανίχνευση ανωμαλιών. Στο πλαίσιο των δικτύων 5G, η μη εποπτευόμενη μάθηση χρησιμοποιείται για την αυτόματη ομαδοποίηση χρηστών με βάση τη συμπεριφορά τους, την κατανόηση της γεωγραφικής και λειτουργικής κατανομής της κυκλοφορίας, καθώς και για τη βελτιστοποίηση της διαχείρισης των slices με τρόπο που προσαρμόζεται δυναμικά στις ανάγκες των εφαρμογών [52].

4.3.1 K-Means Clustering


Ο K-Means είναι ένας από τους πιο διαδεδομένους και εύχρηστους αλγόριθμους ομαδοποίησης. Ο στόχος του είναι να χωρίσει ένα σύνολο δεδομένων σε K ομάδες (clusters), όπου κάθε παρατήρηση ανήκει στο cluster με το κοντινότερο κέντρο (centroid). Η διαδικασία ξεκινά με την τυχαία τοποθέτηση των K αρχικών κέντρων. Έπειτα, εκτελούνται επαναληπτικά δύο βήματα: (α) κάθε σημείο εκχωρείται στο πλησιέστερο κέντρο βάσει Ευκλείδειας απόστασης, και (β) κάθε κέντρο ενημερώνεται ως το μέσο όλων των σημείων που του έχουν ανατεθεί. Η διαδικασία αυτή συνεχίζεται μέχρι τα κέντρα να συγκλίνουν.

Το K-Means υποθέτει ότι τα clusters είναι σφαιρικά και έχουν παρόμοιο μέγεθος, πράγμα που μπορεί να περιορίσει την αποτελεσματικότητά του σε πιο πολύπλοκες κατανομές. Ωστόσο, η απλότητά του και η αποδοτικότητα στην εκτέλεση τον καθιστούν εξαιρετικά χρήσιμο στην πράξη.

Στα δίκτυα 5G, ο K-Means έχει χρησιμοποιηθεί για την ομαδοποίηση χρηστών με βάση τη γεωγραφική τους θέση, τις απαιτήσεις QoS, ή το μοτίβο χρήσης δεδομένων. Για παράδειγμα, μπορεί να εντοπίσει ομάδες χρηστών που παρουσιάζουν παρόμοια κινητικότητα και χρήση bandwidth, επιτρέποντας τη δυναμική κατανομή slices ή την εφαρμογή εξειδικευμένων πολιτικών εξυπηρέτησης. Επιπλέον, χρησιμοποιείται για clustering κυψελών ή σημείων πρόσβασης σε περιβάλλοντα dense small cells, προκειμένου να βελτιστοποιηθεί η χρήση των ραδιοπόρων [53].

Παρόλο που ο K-Means είναι ευαίσθητος στην αρχική τοποθέτηση των κέντρων και μπορεί να συγκλίνει σε τοπικά ελάχιστα, υπάρχουν βελτιώσεις όπως ο αλγόριθμος K-Means++ που επιλέγει πιο στατιστικά σταθερά αρχικά κέντρα και προσφέρει καλύτερη σύγκλιση.

Η Εικόνα 8 παρουσιάζει οπτικοποίηση ενός clustering με χρήση του αλγορίθμου K-Means.



Εικόνα 8: Αναπαράσταση ομαδοποίησης με τον αλγόριθμο K-Means

4.3.2 Gaussian Mixture Models (GMM)


Τα GMMs αποτελούν μία πιο ευέλικτη προσέγγιση στο clustering, σε σύγκριση με τον K-Means, καθώς δεν υποθέτουν ότι τα clusters έχουν ίδια σχήματα και μεγέθη. Ένα GMM προσεγγίζει την κατανομή των δεδομένων ως ένα μείγμα από πολλαπλές Γκαουσιανές κατανομές (Gaussian distributions), η καθεμία από τις οποίες μοντελοποιεί ένα υποσύνολο των δεδομένων.

Η εκπαίδευση του μοντέλου γίνεται συνήθως μέσω του αλγορίθμου Expectation-Maximization (EM), ο οποίος εναλλάσσει δύο βήματα: (α) στο στάδιο E (Expectation), υπολογίζεται η πιθανότητα κάθε δείγμα να ανήκει σε κάθε Gaussian, και (β) στο στάδιο M (Maximization), οι παράμετροι των Gaussians (μέσοι όροι, διασπορές, και βάρη) ενημερώνονται ώστε να μεγιστοποιείται η πιθανότητα του μοντέλου.

Η δύναμη των GMM έγκειται στην ικανότητά τους να μοντελοποιούν επικαλυπτόμενα clusters και πολύπλοκες κατανομές δεδομένων, όπου ο K-Means μπορεί να αποτύχει. Αντί να αποδίδει ένα σημείο αποκλειστικά σε ένα cluster, το GMM υπολογίζει την πιθανότητα συμμετοχής του σε κάθε cluster, παρέχοντας ένα πιο εκλεπτυσμένο μοντέλο.

Στο 5G, τα GMM έχουν χρησιμοποιηθεί για την ομαδοποίηση χρηστών με βάση στατιστικά χαρακτηριστικά χρήσης (π.χ. μέση ταχύτητα, latency, συχνότητα συνδέσεων), ειδικά σε περιβάλλοντα massive MIMO, όπου οι χρήστες μπορεί να παρουσιάζουν πολυδιάστατες και επικαλυπτόμενες συμπεριφορές. Επιπλέον, βρίσκουν εφαρμογή στην πρόβλεψη κυκλοφορίας, στη δυναμική ταξινόμηση slices, και στην αναγνώριση προτύπων σε μεταβαλλόμενες συνθήκες καναλιού.

Η ευελιξία των GMM τα καθιστά ιδανικά για περιπτώσεις όπου τα δεδομένα δεν κατανέμονται ισομερώς ή περιέχουν θόρυβο, ωστόσο συνοδεύονται από αυξημένες υπολογιστικές απαιτήσεις και ευαισθησία στην αρχικοποίηση των παραμέτρων.



Εικόνα 9: Παράδειγμα GMM με τρία επικαλυπτόμενα clusters.


4.3.3 Density-Based Spatial Clustering of Applications with Noise (DBSCAN)

Ο αλγόριθμος DBSCAN είναι μία δημοφιλής τεχνική μη εποπτευόμενης μάθησης που βασίζεται στην πυκνότητα των δεδομένων. Σε αντίθεση με τον K-Means ή τα GMM, δεν απαιτεί εκ των προτέρων τον καθορισμό του αριθμού των clusters, και μπορεί να εντοπίσει clusters με αυθαίρετα σχήματα, καθώς και να αναγνωρίσει δεδομένα εκτός κλίμακας (outliers).

Η βασική αρχή λειτουργίας του DBSCAN είναι η εντόπιση περιοχών υψηλής πυκνότητας στο χώρο των χαρακτηριστικών. Ορίζονται δύο βασικές παράμετροι: η απόσταση ϵ (epsilon) και το ελάχιστο πλήθος σημείων (MinPts). Ένα σημείο θεωρείται πυρήνας (core point) αν περιβάλλεται από τουλάχιστον MinPts σημεία εντός ακτίνας ϵ . Στη συνέχεια, όλα τα σημεία που βρίσκονται στην εμβέλεια ενός πυρήνα συνδέονται στο ίδιο cluster, ενώ τα σημεία που δεν συνδέονται με κανέναν πυρήνα θεωρούνται θόρυβος ή ανωμαλίες.

Ο DBSCAN είναι ιδανικός για datasets με μεταβλητή πυκνότητα και ιδιαίτερα ανθεκτικός στην παρουσία θορύβου. Στα δίκτυα 5G, έχει χρησιμοποιηθεί για την ανίχνευση ανωμαλιών κυκλοφορίας (traffic anomaly detection), π.χ. ξαφνικών εκρήξεων στη χρήση δεδομένων που μπορεί να σχετίζονται με κυβερνοεπιθέσεις ή σφάλματα εξοπλισμού. Επίσης, μπορεί να χρησιμοποιηθεί για την ομαδοποίηση χρηστών σε περιβάλλοντα με σύνθετη γεωμετρία, όπως πυκνά αστικά δίκτυα όπου η τοπολογική κατανομή δεν είναι ομοιογενής [54].

MinPts = 5



Εικόνα 10: Παράδειγμα DBSCAN clustering.


4.3.4 Φασματική Ομαδοποίηση (Spectral Clustering)

Το Spectral Clustering αποτελεί μία εξελιγμένη τεχνική ομαδοποίησης που βασίζεται στη θεωρία γραφημάτων και στην φασματική ανάλυση. Σε αντίθεση με τους κλασικούς αλγορίθμους όπως το K-Means, που βασίζονται κυρίως σε αποστάσεις στο ευκλείδιο χώρο, το Spectral Clustering εκμεταλλεύεται την πληροφορία γειτνίασης των σημείων και τη δομή του υποκείμενου γράφου για να εντοπίσει μη γραμμικά διαχωρίσιμα clusters.

Η διαδικασία ξεκινά με την κατασκευή ενός γραφήματος ομοιότητας μεταξύ των δεδομένων, συνήθως με βάση τον πίνακα γειτνίασης ή τον πυρήνα RBF. Στη συνέχεια υπολογίζεται ο Λαπλασιανός πίνακας του γράφου, του οποίου οι ιδιοτιμές και ιδιοδιανύσματα χρησιμοποιούνται για την αναπαράσταση των δεδομένων σε έναν χαμηλότερης διάστασης φασματικό χώρο. Εκεί, οι παρατηρήσεις ομαδοποιούνται με έναν παραδοσιακό αλγόριθμο όπως ο K-Means, αλλά σε έναν μετασχηματισμένο χώρο όπου τα clusters είναι γραμμικά διαχωρίσιμα.

Το Spectral Clustering έχει σημαντικά πλεονεκτήματα: μπορεί να ανιχνεύσει αυθαίρετου σχήματος και μη σφαιρικά clusters, ενώ είναι ευέλικτο ως προς τον αριθμό και τη μορφή των cluster. Παρόλα αυτά, είναι πιο ευαίσθητο στην επιλογή των παραμέτρων (π.χ., αριθμός clusters, εύρος kernel) και απαιτεί υπολογιστικά έντονη φασματική αποικοδόμηση, γεγονός που το καθιστά λιγότερο πρακτικό για εξαιρετικά μεγάλα σύνολα δεδομένων.

Στα δίκτυα 5G, το Spectral Clustering έχει χρησιμοποιηθεί για την τμηματοποίηση τοπολογιών χρηστών και σταθμών βάσης, τον εντοπισμό κοινοτήτων σε δικτυακούς γράφους επικοινωνίας, καθώς και για την ανάλυση σχέσεων αλληλεπίδρασης μεταξύ slices σε ετερογενή περιβάλλοντα. Η δυνατότητά του να αποκαλύπτει κρυφές σχέσεις σε δεδομένα υψηλής διασύνδεσης το καθιστά ιδανικό για εφαρμογές σε δίκτυα C-RAN, virtualized network functions και δυναμική ομαδοποίηση χρηστών με βάση κοινά μοτίβα συμπεριφοράς [55].



Εικόνα 11: Παράδειγμα Spectral clustering.


4.4 Ενισχυτική Μάθηση (Reinforcement Learning)

Η ενισχυτική μάθηση αποτελεί έναν ιδιαίτερο κλάδο της ΜΜ που διαφέρει από την εποπτευόμενη και τη μη εποπτευόμενη μάθηση, καθώς βασίζεται στην αλληλεπίδραση ενός πράκτορα (agent) με το περιβάλλον. Αντί να μαθαίνει από προκαθορισμένα παραδείγματα ή ετικέτες, ο πράκτορας ανακαλύπτει ποια ενέργεια να εκτελέσει σε κάθε κατάσταση μέσω μιας διαδικασίας δοκιμής και σφάλματος, με στόχο τη μεγιστοποίηση της σωρευτικής ανταμοιβής (reward).

Η βασική ιδέα πίσω από την ενισχυτική μάθηση είναι η έννοια του κύκλου: ο πράκτορας παρατηρεί την κατάσταση του περιβάλλοντος (state), εκτελεί μία ενέργεια (action), και λαμβάνει ως αποτέλεσμα μία ανταμοιβή. Με βάση αυτή την ανατροφοδότηση, ο πράκτορας τροποποιεί την πολιτική του (policy), δηλαδή τη στρατηγική που ακολουθεί για την επιλογή ενεργειών. Το πρόβλημα μοντελοποιείται συνήθως ως μία Μαρκοβιανή Διαδικασία Απόφασης (Markov Decision Process - MDP), που περιλαμβάνει σύνολο καταστάσεων, ενεργειών, συναρτήσεις μετάβασης και συναρτήσεις ανταμοιβής [56].

Οι πιο βασικοί αλγόριθμοι ενισχυτικής μάθησης περιλαμβάνουν το Q-learning, το οποίο χρησιμοποιεί πίνακες για την εκτίμηση της αξίας κάθε κατάστασης-ενέργειας, και τις τεχνικές policy gradient όπως το Proximal Policy Optimization (PPO), που βελτιώνουν άμεσα την πολιτική βάσει παρατηρούμενων επιδόσεων. Επιπλέον, η ενσωμάτωση βαθιών νευρωνικών δικτύων οδηγεί στη δημιουργία αλγορίθμων όπως τα Deep Q Networks (DQN), που μπορούν να χειριστούν μεγάλους και συνεχείς χώρους καταστάσεων.

Η ενισχυτική μάθηση είναι ιδιαίτερος χρήσιμη στα 5G δίκτυα καθώς μπορεί να λάβει αποφάσεις σε δυναμικά και αβέβαια περιβάλλοντα. Ενδεικτικές εφαρμογές περιλαμβάνουν: τη βέλτιστη διαχείριση handovers, όπου ο πράκτορας επιλέγει τη βέλτιστη χρονική στιγμή και σταθμό βάσης για αλλαγή σύνδεσης, την έξυπνη κατανομή πόρων μεταξύ slices με διαφορετικές απαιτήσεις QoS, την ενεργειακά αποδοτική διαχείριση του scheduling, τη δυναμική διαχείριση φάσματος και παρεμβολών σε πυκνά αστικά περιβάλλοντα· και την ενίσχυση της αυτονομίας και της ευφυΐας των δικτύων μέσω διαδικασιών self-optimization. Η Εικόνα 12 παρουσιάζει ένα εννοιολογικό διάγραμμα λειτουργίας ενισχυτικής μάθησης, όπου φαίνεται ο κύκλος αλληλεπίδρασης μεταξύ πράκτορα και περιβάλλοντος με ανατροφοδότηση μέσω ανταμοιβής.



Εικόνα 12: Διάγραμμα λειτουργίας ενισχυτικής μάθησης

4.4.1 Q-Learning

Το Q-learning αποτελεί μία από τις πιο θεμελιώδεις και ευρέως χρησιμοποιούμενες μεθόδους ενισχυτικής μάθησης. Πρόκειται για έναν αλγόριθμο εκτός πολιτικής (off-policy), που επιδιώκει να μάθει την τιμή της βέλτιστης πολιτικής ανεξαρτήτως της πολιτικής που ακολουθεί ο πράκτορας κατά τη διάρκεια της εκπαίδευσης. Η βασική ιδέα είναι να δημιουργηθεί ένας πίνακας Q, ο οποίος αντιστοιχεί σε τιμές ποιότητας (Q-values) για κάθε συνδυασμό κατάστασης και ενέργειας.

Η ενημέρωση του πίνακα Q πραγματοποιείται μέσω της ακόλουθης σχέσης:

$$Q(s, a) \leftarrow Q(s, a) + \alpha[r + \gamma * \max_{a'} Q(s', a') - Q(s, a)]$$


Όπου:

- $Q(s, a)$ είναι η τιμή Q για την τρέχουσα κατάσταση s και την ενέργεια a,
- α είναι ο ρυθμός μάθησης (learning rate),

- γ είναι ο συντελεστής απόσβεσης (discount factor),
- r είναι η ανταμοιβή που λαμβάνεται μετά την εκτέλεση της ενέργειας a στην κατάσταση s ,
- $\max Q(s', a')$ είναι η μέγιστη εκτιμώμενη μελλοντική τιμή από την επόμενη κατάσταση s' .

Το Q-learning μπορεί να οδηγήσει σε βέλτιστες πολιτικές ακόμη και όταν ο πράκτορας εξερευνά τυχαία το περιβάλλον του. Ωστόσο, δεν κλιμακώνεται καλά σε περιβάλλοντα με μεγάλους ή συνεχείς χώρους καταστάσεων, γεγονός που οδήγησε στην ανάπτυξη των DQN

Στα δίκτυα 5G, το Q-learning έχει χρησιμοποιηθεί επιτυχώς για την επιλογή σταθμού βάσης, την προσαρμοστική κατανομή φάσματος, την αποφυγή παρεμβολών και τη διαχείριση κυκλοφορίας με στόχο τη βελτιστοποίηση της εμπειρίας του χρήστη και της απόδοσης του συστήματος [57].



Εικόνα 13: Δομή πίνακα Q (Q-table) στο Q-learning

4.4.2 Deep Q Networks (DQN)

Τα DQN συνιστούν μία ισχυρή επέκταση του βασικού Q-learning, σχεδιασμένη ώστε να ξεπερνά τους περιορισμούς που προκύπτουν σε περιβάλλοντα με μεγάλες διαστάσεις καταστάσεων. Αντί για πίνακα Q, τα DQN χρησιμοποιούν ένα βαθύ νευρωνικό δίκτυο για να προσεγγίσουν τη συνάρτηση $Q(s, a)$, δηλαδή να εκτιμήσουν την τιμή της κάθε ενέργειας σε μία δεδομένη κατάσταση.


Η εκπαίδευση του νευρωνικού δικτύου βασίζεται σε δεδομένα από αλληλεπιδράσεις του πράκτορα με το περιβάλλον, τα οποία αποθηκεύονται σε μία μνήμη εμπειριών (experience replay buffer). Από αυτή τη μνήμη αντλούνται τυχαία δείγματα (mini-batches) ώστε να μειωθεί η συσχέτιση μεταξύ διαδοχικών εμπειριών και να σταθεροποιηθεί η διαδικασία εκμάθησης. Παράλληλα, χρησιμοποιείται ένα σταθερό target network, το οποίο ενημερώνεται περιοδικά, ώστε να υπολογίζεται ο στόχος της εκπαίδευσης με τρόπο πιο σταθερό και ασφαλές.

Η συνάρτηση κόστους στα DQN είναι συνήθως το μέσο τετράγωνο σφάλμα μεταξύ της εκτιμώμενης τιμής Q και της αναμενόμενης τιμής με βάση την τρέχουσα ανταμοιβή και τη μέγιστη μελλοντική τιμή:

$$L(\theta) = E[(r + \gamma * \max Q_target(s', a') - Q(s, a; \theta))^2]$$

Όπου θ είναι οι παράμετροι του κύριου δικτύου και Q_target αναφέρεται στο target network [58].

Στο πλαίσιο των δικτύων 5G, τα DQN έχουν εφαρμοστεί εκτενώς για την κατανομή φάσματος, τη διαχείριση παρεμβολών σε περιβάλλοντα ultra-dense, την προσαρμοστική κατανομή χρηστών σε σταθμούς βάσης και την υποστήριξη decision making σε scenarios με πολλές μεταβλητές. Η δυνατότητα των DQN να γενικεύουν σε μεγάλους χώρους καταστάσεων και να μαθαίνουν από εμπειρία χωρίς εποπτεία τα καθιστά εξαιρετικά χρήσιμα για προβλήματα όπου η απόφαση πρέπει να λαμβάνεται γρήγορα και με ακρίβεια σε πραγματικό χρόνο [59].



Εικόνα 14: Δομή DQN


4.4.3 Proximal Policy Optimization (PPO)

Το PPO αποτελεί μία από τις πιο προηγμένες τεχνικές ενισχυτικής μάθησης με βάση τις πολιτικές (policy-based RL). Σε αντίθεση με το Q-learning ή τα DQN που βασίζονται στην εκτίμηση συναρτήσεων αξίας (value functions), το PPO επικεντρώνεται στην άμεση βελτιστοποίηση της πολιτικής του πράκτορα, δηλαδή του μηχανισμού με τον οποίο επιλέγονται οι ενέργειες.

Ο κύριος στόχος του PPO είναι να βελτιώνει σταδιακά την πολιτική διατηρώντας την ταυτόχρονα κοντά στην προηγούμενη εκδοχή της, ώστε να αποφεύγονται απότομες και αποσταθεροποιητικές αλλαγές. Αυτό επιτυγχάνεται με την εισαγωγή ενός όρου «περιορισμού» στη συνάρτηση απώλειας, ο οποίος επιτρέπει μόνο περιορισμένες ενημερώσεις στο λόγο πιθανότητας μεταξύ της νέας και της παλιάς πολιτικής (clipped objective function) [60].

Το PPO προσφέρει υψηλή απόδοση και σταθερότητα και θεωρείται state-of-the-art για προβλήματα με συνεχείς ή πολύπλοκες ενέργειες. Η εκπαίδευση γίνεται μέσω τεχνικών όπως Generalized Advantage Estimation (GAE), που επιτρέπουν καλύτερη εκμετάλλευση της ανταμοιβής. Επίσης, χρησιμοποιεί mini-batch updates και πολλαπλές επαναλήψεις για κάθε δεδομένο, γεγονός που ενισχύει τη σταθερότητα και την αποτελεσματικότητα της εκμάθησης.

Στα δίκτυα 5G, το PPO έχει χρησιμοποιηθεί για ενεργειακά αποδοτικό scheduling, για πολιτικές μεταγωγής (handover policies) που λαμβάνουν υπόψη τόσο το QoS όσο και το ενεργειακό αποτύπωμα, καθώς και για την κατανομή πόρων σε περιβάλλοντα με πολλαπλά slices και ετερογενείς απαιτήσεις. Επιπλέον, η δυνατότητά του να αντιμετωπίζει περιβάλλοντα με συνεχείς καταστάσεις και ενέργειες το καθιστά ιδανικό για χρήση σε αυτόνομα, ευφυή 5G δίκτυα [61].



Εικόνα 15: Βασική αρχιτεκτονική PPO

5

Πειραματικά Αποτελέσματα

5.1 Περιγραφή Πειραματικής Διαδικασίας

Το παρόν κεφάλαιο περιγράφει την υλοποίηση των αλγορίθμων που εφαρμόστηκαν στο πείραμα της διπλωματικής εργασίας, με σκοπό τη βελτίωση της κατανομής πόρων σε δίκτυα 5G μέσω μη εποπτευόμενης μάθησης. Εξετάζονται οι μέθοδοι K-means, GMM, DBSCAN, και Spectral Clustering, με έμφαση στις τεχνικές λεπτομέρειες, τη βελτιστοποίηση παραμέτρων, τις μετρικές αξιολόγησης, τις μαθηματικές βάσεις των αλγορίθμων, καθώς και τις οπτικοποιήσεις που χρησιμοποιήθηκαν για την αξιολόγησή τους. Η υλοποίηση πραγματοποιήθηκε στη γλώσσα προγραμματισμού Python, αξιοποιώντας βιβλιοθήκες όπως οι scikit-learn, NumPy, Pandas, Matplotlib και Seaborn, εξασφαλίζοντας ευελιξία, ακρίβεια και οπτική σαφήνεια στην επεξεργασία δεδομένων και στην παρουσίαση των αποτελεσμάτων.

5.1.1 Υλοποίηση του Πειράματος

Η υλοποίηση του πειράματος βασίστηκε σε ένα συνθετικό σύνολο δεδομένων που περιλαμβάνει 10.000 δείγματα, κατανομημένα ισομερώς σε πέντε τύπους slices 5G: eMBB, URLLC, mMTC, Vehicle-to-everything (V2X) και IoT-HD, με 2.000 δείγματα ανά τύπο. Κάθε δείγμα περιέχει τα χαρακτηριστικά bandwidth, latency, απόσταση από τον πλησιέστερο σταθμό βάσης (distance_to_bs) και χωρικές συντεταγμένες (x, y) σε μια περιοχή διαστάσεων 100x100 μέτρων. Για την προσομοίωση ενός ρεαλιστικού δικτύου, τοποθετήθηκαν τρεις σταθμοί βάσης τυχαία, με την περιοριστική συνθήκη ότι η ελάχιστη απόσταση μεταξύ τους ήταν 30 μέτρα, ώστε να αποφευχθεί η υπερβολική συγκέντρωση. Η εκχώρηση των χρηστών στους σταθμούς βάσης πραγματοποιήθηκε με βάση την ελάχιστη ευκλείδεια απόσταση, υπολογισμένη ως:

$$d(u, b) = \sqrt{(x_u - x_b)^2 + (y_u - y_b)^2}$$

όπου (x_u, y_u) είναι οι συντεταγμένες του χρήστη και (x_b, y_b) οι συντεταγμένες του σταθμού βάσης. Η απόσταση αυτή χρησιμοποιήθηκε για την ανάθεση κάθε χρήστη στον πλησιέστερο σταθμό βάσης, με την απόσταση να καταγράφεται ως χαρακτηριστικό `distance_to_bs`.

Η προεπεξεργασία των δεδομένων περιλάμβανε τη λογαριθμική μετατροπή (`log1p`) των χαρακτηριστικών `bandwidth`, `latency` και απόστασης για να μειωθεί η ασυμμετρία των κατανομών τους, χρησιμοποιώντας τη συνάρτηση:

$$x' = \log(1 + x)$$

Επίσης, πραγματοποιήθηκε κανονικοποίηση των δεδομένων με τη μέθοδο `StandardScaler`, που μετατρέπει κάθε χαρακτηριστικό ώστε να έχει μηδενικό μέσο όρο και μοναδιαία διακύμανση:

$$x_{scaled} = \frac{x - \mu}{\sigma}$$

όπου μ είναι ο μέσος όρος και σ η τυπική απόκλιση του χαρακτηριστικού. Οι συντεταγμένες x και y διατηρήθηκαν χωρίς επεξεργασία για χρήση στις οπτικοποιήσεις τοπολογίας. Η διαδικασία προεπεξεργασίας εξασφάλισε ότι τα δεδομένα ήταν κατάλληλα για την εκπαίδευση των αλγορίθμων, αποφεύγοντας προβλήματα όπως μηδενικές ή άπειρες τιμές, με έλεγχο για την παρουσία τέτοιων τιμών.

5.2 Αλγόριθμοι Μη Εποπτευόμενης Μάθησης

5.2.1 K-means

Η μέθοδος K-means είναι ένας αλγόριθμος ομαδοποίησης που χωρίζει τα δεδομένα σε k clusters, ελαχιστοποιώντας τη διακύμανση εντός των cluster μέσω της μετρικής Within-Cluster Sum of Squares (WCSS), ορίζεται ως:

$$WCSS = \sum_{i=1}^k \sum_{x \in C_i} \|x - \mu_i\|^2$$


όπου C_i είναι το cluster i , μ_i το κεντροειδές του cluster και $\|\cdot\|$ η ευκλείδεια απόσταση [62]. Η βελτιστοποίηση του αριθμού των k cluster πραγματοποιήθηκε μέσω μιας υβριδικής προσέγγισης που συνδύασε το Silhouette Score και τη μέθοδο Elbow. Το Silhouette Score για ένα δείγμα x_i υπολογίζεται ως:

$$s(x_i) = \frac{b(x_i) - a(x_i)}{\max(a(x_i), b(x_i))}$$

όπου $a(x_i)$ είναι η μέση απόσταση του x_i από τα άλλα σημεία του ίδιου cluster και $b(x_i)$ η μέση απόσταση από τα σημεία του πλησιέστερου άλλου cluster. Το συνολικό Silhouette


Score είναι ο μέσος όρος όλων των $s(x_i)$, με τιμές από -1 έως 1, όπου υψηλότερες τιμές υποδεικνύουν καλύτερη ομαδοποίηση [63]. Το κανονικοποιημένο WCSS, δηλαδή το WCSS κλιμακωμένο στο εύρος $[0, 1]$, χρησιμοποιήθηκε για τον εντοπισμό του σημείου καμπής στη μέθοδο Elbow, μέσω της δεύτερης παραγώγου της καμπύλης WCSS. Η τελική επιλογή του k έγινε επιλέγοντας τη μικρότερη τιμή της οποίας το Silhouette Score ήταν εντός 5% της μέγιστης τιμής, με τη μέθοδο Elbow να λειτουργεί ως επικυρωτικό κριτήριο. Αυτή η προσέγγιση εξασφάλισε ότι ο αριθμός των cluster ήταν ταυτόχρονα αποδοτικός και ερμηνεύσιμος, αντικατοπτρίζοντας τις πέντε κατηγορίες slices 5G.

Για την οπτικοποίηση των αποτελεσμάτων, δημιουργήθηκαν δύο γραφήματα που απεικονίζουν τη διαδικασία βελτιστοποίησης. Το πρώτο γράφημα παρουσιάζει το κανονικοποιημένο WCSS έναντι του k , με μια διακεκομμένη γραμμή να υποδεικνύει το βέλτιστο k (Εικόνα 16).



Εικόνα 16: Καμπύλη Elbow για τη μέθοδο K-means

Το δεύτερο γράφημα δείχνει το Silhouette Score για κάθε τιμή του k , επισημαίνοντας επίσης το βέλτιστο k (Εικόνα 17).



Εικόνα 17: Καμπύλη Silhouette Score για τη μέθοδο K-means

Ο Πίνακας 1 συνοψίζει τα αποτελέσματα της βελτιστοποίησης, παρουσιάζοντας τις τιμές WCSS, Silhouette Score και τον αριθμό μοναδικών ετικετών για κάθε k .

Πίνακας 1: Αποτελέσματα K-means για $k=2$ έως $k=10$

k	WCSS	Silhouette Score
2	20339.97	0.3091
3	14655.06	0.3663
4	10328.68	0.3971
5	7770.62	0.4477
6	6701.97	0.4460
7	5703.55	0.4456
8	4820.41	0.4409
9	4145.87	0.4512
10	3734.89	0.4399

Η επιλογή του $k=5$ ήταν η βέλτιστη, καθώς το Silhouette Score έφτανε τη 2^η μέγιστη τιμή του (0.4477), ενώ η μέθοδος Elbow επιβεβαίωσε το σημείο καμπής κοντά στο $k=5$, αντικατοπτρίζοντας τον αριθμό των slices 5G.

Ο αλγόριθμος K-means λειτουργεί ως εξής: ξεκινάμε επιλέγοντας τυχαία k σημεία από το σύνολο δεδομένων ως αρχικά centroids. Σε κάθε επανάληψη, ανατίθεται κάθε δείγμα στο πλησιέστερο κέντρο (βασισμένοι στην Ευκλείδεια απόσταση) και έπειτα υπολογίζεται εκ

νέου το κέντρο κάθε cluster ως ο μέσος όρος των δειγμάτων που της έχουν ανατεθεί. Αυτή η διαδικασία “ανάθεσης” και “ενημέρωσης” επαναλαμβάνεται μέχρι οι μετατοπίσεις των κέντρων να είναι μικρότερες από ένα προκαθορισμένο όριο σύγκλισης, διασφαλίζοντας ότι το WCSS βρίσκεται σε τοπικό ελάχιστο. Παρακάτω παρατίθεται ένας μικρός ψευδοκώδικας.

Input:

X = σύνολο n δειγμάτων
 k = αριθμός clusters
 ε = όριο σύγκλισης

Output:

$C = \{c_1, \dots, c_k\}$ κέντρα clusters

1. Αρχικοποίηση:

• $C \leftarrow$ τυχαία k δείγματα από X

2. Επανάληψη μέχρι $\max_j \|c_j^{(t)} - c_j^{(t-1)}\| < \varepsilon$:

a. (Assignment)

για κάθε $x_i \in X$:

- υπολόγισε $d(x_i, c_j)$ για $j=1 \dots k$
 - $j^* \leftarrow \operatorname{argmin}_j d(x_i, c_j)$
 - ανάθεσε x_i στο cluster j^*

b. (Update)


για κάθε $j=1 \dots k$:

- $c_j \leftarrow \operatorname{mean}(\{x_i \mid x_i \text{ ανατέθηκαν στο } j\})$

3. Επιστροφή C

Ψευδοκώδικας 1: Ψευδοκώδικας *K-means*

Για την προβολή των cluster (Εικόνα 18), χρησιμοποιήθηκε η μέθοδος t-SNE (t-distributed Stochastic Neighbor Embedding), η οποία μειώνει τη διάσταση των δεδομένων σε δύο διαστάσεις διατηρώντας την τοπική δομή [64].

Εικόνα 18: *t-SNE* προβολή των *cluster K-means*

5.2.2 Gaussian Mixture Models (GMM)


Η μέθοδος GMM επιλέχθηκε για την ικανότητά της να μοντελοποιεί δεδομένα ως συνδυασμούς κανονικών κατανομών, επιτρέποντας την ακριβή ανάθεση σε clusters με πιθανότητες, σε αντίθεση με την απλή κατανομή των δεδομένων. Η πιθανότητα ενός δείγματος x δίνεται από:

$$p(x) = \sum_{k=1}^K \pi_k N(x | \mu_k, \Sigma_k)$$

όπου π_k είναι το βάρος της συνιστώσας k , $N(x | \mu_k, \Sigma_k)$ η γκαουσιανή κατανομή με μέσο όρο μ_k και πίνακα συνδιακύμανσης Σ_k , και $\sum_k \pi_k = 1$ [65]. Η βελτιστοποίηση του k έγινε δοκιμάζοντας τιμές από 2 έως 10, αξιολογώντας το Silhouette Score και το Bayesian Information Criterion (BIC):


$$BIC = -2 \ln(\hat{L}) + \mu \ln(n)$$

Η οπτικοποίηση των αποτελεσμάτων περιλάμβανε δύο γραφήματα που απεικονίζουν τη διαδικασία βελτιστοποίησης. Το πρώτο γράφημα παρουσιάζει το Silhouette Score για κάθε k , με μια διακεκομμένη γραμμή να υποδεικνύει το βέλτιστο k (Εικόνα 19).



Εικόνα 19: Καμπύλη Silhouette Score για τη μέθοδο GMM

Το δεύτερο γράφημα δείχνει το κανονικοποιημένο BIC έναντι του k , επισημαίνοντας την επιλεγμένη τιμή (Εικόνα 20).



Εικόνα 20: Καμπύλη κανονικοποιημένου BIC για τη μέθοδο GMM

Ο Πίνακας 2 συνοψίζει τα αποτελέσματα, παρουσιάζοντας το Silhouette Score, το BIC και τον αριθμό μοναδικών ετικετών για κάθε k .

Πίνακας 2: Αποτελέσματα GMM για k=2 έως k=10

k	BIC	Silhouette Score
2	69615.88	0.3409
3	55868.62	0.3663
4	35252.62	0.3198
5	33345.68	0.3967
6	33050.72	0.3963
7	32391.21	0.4369
8	32193.03	0.4183
9	31927.29	0.4507
10	31967.71	0.4271

Επιλογή του k=7 επιλέχθηκε ως η βέλτιστη γιατί το Silhouette Score για k=7 ήταν 0.4369, το δεύτερο υψηλότερο μετά το k=9 (0.4507) συνδυάζοντας το χαμηλό BIC για k=7 (32391.21) το οποίο αν και πολύ κοντά στο ελάχιστο BIC (31927.29) για k=9 προσφέρει καλή ισορροπία μεταξύ προσαρμογής και πολυπλοκότητας μοντέλου.

Ο GMM χρησιμοποιεί την Expectation–Maximization για να εκτιμήσει τις παραμέτρους μίξης ενός μιγμάτων Γκαουσιανών. Στο E-step υπολογίζονται “μαλακές” (soft) αναθέσεις $\gamma_i(m)$ βάσει του τρέχοντος μοντέλου, και στο M-step οι παράμετροι ενημερώνονται για να μεγιστοποιήσουν τη συνολική πιθανότητα των δεδομένων. Η διαδικασία επαναλαμβάνεται έως ότου η αύξηση του log-likelihood γίνει αμελητέα, εξασφαλίζοντας σύγκλιση σε τοπικό μέγιστο.

Input:

X = σύνολο n δειγμάτων

M = αριθμός συστατικών (components)

ε = όριο σύγκλισης

Output:

$\Theta = \{\pi_1 \dots \pi_M, \mu_1 \dots \mu_M, \Sigma_1 \dots \Sigma_M\}$ παράμετροι μίξης

1. Αρχικοποίηση:

• τυχαία ή με K-means εκτιμήστε μ_m , Σ_m και $\pi_m = 1/M$

2. Επανάληψη έως ότου $\Delta \ell < \varepsilon$ ($\ell = \log\text{-likelihood}$):

a. (E-step) για κάθε $x_i \in X$ και κάθε $m=1 \dots M$:

- $\gamma_i(m) \leftarrow \pi_m \cdot \mathcal{N}(x_i | \mu_m, \Sigma_m) / \sum_{j=1}^M \pi_j \cdot \mathcal{N}(x_i | \mu_j, \Sigma_j)$

b. (M-step) για κάθε m :

- $N_m \leftarrow \sum_{i=1}^n \gamma_i(m)$

- $\mu_m \leftarrow (1/N_m) \sum_{i=1}^n \gamma_i(m) \cdot x_i$


- $\Sigma_m \leftarrow (1/N_m) \sum_{i=1}^n \gamma_i(m) \cdot (x_i - \mu_m)(x_i - \mu_m)^T$

- $\pi_m \leftarrow N_m / n$

3. Επιστροφή Θ

Ψευδοκώδικας 2: Ψευδοκώδικας GMM

Για την προβολή των cluster, η μέθοδος t-SNE, με τις ίδιες παραμέτρους όπως στην K-means (perplexity=50, 1000 επαναλήψεις), χρησιμοποιήθηκε για τη δημιουργία διδιάστατων διαγραμμάτων, με τα κεντροειδή να υπολογίζονται στον t-SNE χώρο. Τα σημεία απεικονίστηκαν με διαφάνεια 0.2 και μέγεθος 30, ενώ περιγράμματα πυκνότητας (KDE) προστέθηκαν για την ανάδειξη της πυκνότητας των cluster (Εικόνα 21).



Εικόνα 21: t-SNE προβολή των cluster GMM

5.2.3 Density-Based Spatial Clustering of Applications with Noise (DBSCAN)

Η μέθοδος DBSCAN [66], ομαδοποιεί τα δεδομένα με βάση την πυκνότητα, χωρίς την ανάγκη προκαθορισμού του αριθμού των cluster. Ένα σημείο ταξινομείται ως πυρήνας αν έχει τουλάχιστον min_samples σημεία εντός ακτίνας eps , ως περιθώριο αν βρίσκεται εντός της ακτίνας αλλά δεν είναι πυρήνας, ή ως θόρυβος αν δεν ανήκει σε κανένα cluster. Η πυκνότητα ορίζεται μέσω της παραμέτρου eps , που καθορίζει την ακτίνα της γειτονιάς, και της παραμέτρου min_samples , που ορίζει τον ελάχιστο αριθμό σημείων για τη δημιουργία πυρήνα. Η βελτιστοποίηση επικεντρώθηκε στις παραμέτρους eps και min_samples μέσω αναζήτησης πλέγματος, δοκιμάζοντας τιμές eps από 0.3 έως 0.6 και min_samples από 50 έως 150. Για κάθε συνδυασμό, υπολογίστηκε το Silhouette Score, περιορίζοντας την αξιολόγηση σε περιπτώσεις με τουλάχιστον δύο clusters και ποσοστό θορύβου μικρότερο από 50%:

$$\text{Noise \%} = \frac{\# \text{ Σημεία θορύβου}}{\# \text{ Δειγμάτων}} * 100$$

Ο Πίνακας 3 συνοψίζει τα αποτελέσματα της βελτιστοποίησης, παρουσιάζοντας το Silhouette Score, τον αριθμό cluster και το ποσοστό θορύβου για κάθε συνδυασμό ϵ και $\min_samples$.

Πίνακας 3: Αποτελέσματα DBSCAN για διάφορους συνδυασμούς ϵ και $\min_samples$

ϵ	$\min_samples$	Silhouette Score	Clusters	Noise %
0.3	50	0.3753	5	5.26
0.3	100	0.4079	5	12.17
0.3	150	0.4335	5	19.92
0.4	50	0.3581	5	2.32
0.4	100	0.3770	5	5.39
0.4	150	0.3987	5	9.43
0.5	50	0.4180	4	1.17
0.5	100	0.4324	4	3.11
0.5	150	0.4420	4	4.88
0.6	50	0.4144	4	0.73
0.6	100	0.4244	4	1.92
0.6	150	0.4313	4	2.92

Η επιλογή του συνδυασμού $\epsilon=0.5$, $\min_samples=150$ προτιμήθηκε λόγω του υψηλού Silhouette Score (0.4420) και του χαμηλού ποσοστού θορύβου (4.88%), με τέσσερα clusters να αντικατοπτρίζουν επαρκώς τη δομή των δεδομένων, αν και ελαφρώς λιγότερες από τις πέντε κατηγορίες slices.

Το DBSCAN βρίσκει πυρήνες πυκνότητας και επεκτείνει clusters γύρω τους. Κάθε δείγμα ταξινομείται ως core ($|N| \geq \min_pts$), border ή noise. Οι πυρήνες συνδέονται μέσω επαναληπτικής επέκτασης, αναγνωρίζοντας σχήματα οποιασδήποτε μορφής χωρίς να χρειάζεται προκαθορισμένος αριθμός clusters.

Input:

X = σύνολο n δειγμάτων
 ϵ = ακτίνα γειτνίασης
 $\min_pts$ = ελάχιστος αριθμός γειτόνων

Output:

L = ετικέτες clusters ή noise

1. $L[i] \leftarrow UNVISITED$ για όλα τα x_i

2. για κάθε $x_i \in X$:

a. αν $L[i] \neq UNVISITED$: συνέχισε

b. $N \leftarrow \{x_j \mid \text{dist}(x_i, x_j) \leq \epsilon\}$

c. αν $|N| < \min_pts$:

$L[i] \leftarrow NOISE$

```


αλλιώς:
    new_cluster
    expand(xi, N, ε, min_pts, L)
3. Επιστροφή L

function expand(x, N, ε, min_pts, L):
    add x σε τρέχον cluster
    για κάθε y ∈ N:
        αν L[y] = NOISE: L[y] ← current cluster
        αν L[y] = UNVISITED:
            L[y] ← current cluster
            N' ← {z | dist(y,z) ≤ ε}
            αν |N'| ≥ min_pts: N ← N ∪ N'

```

Ψευδοκώδικας 2: Ψευδοκώδικας DBSCAN

Η οπτικοποίηση των αποτελεσμάτων περιλάμβανε τη χρήση της μεθόδου t-SNE, με τις ίδιες παραμέτρους όπως προηγουμένως, για τη δισδιάστατη προβολή των cluster. Τα σημεία θορύβου απεικονίστηκαν σε μαύρο χρώμα, με διαφάνεια 0.05 και μέγεθος 20, ώστε να μειωθεί η οπτική επιβάρυνση, ενώ τα clusters παρουσιάστηκαν με χρώματα και περιγράμματα KDE για την ανάδειξη της πυκνότητας (Εικόνα 22).



Εικόνα 22: t-SNE προβολή των cluster DBSCAN

5.2.4 Φασματική Ομαδοποίηση (Spectral Clustering)

Η μέθοδος Spectral Clustering ομαδοποιεί δεδομένα με βάση τη δομή ομοιότητας αξιοποιώντας τη θεωρία γράφων [67]. Δημιουργεί έναν πίνακα ομοιότητας με πυρήνα Gaussian (Radial Basis Function, RBF), υπολογίζει τον πίνακα Laplace και προβαίνει σε

ανάλυση για τη μείωση της διαστατικότητας. Η ομοιότητα μεταξύ δύο σημείων x_i και x_j ορίζεται ως:

$$s(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$$

όπου $\|x_i - x_j\|$ είναι η ευκλείδεια απόσταση και σ η παράμετρος κλίμακας του πυρήνα. Από τον πίνακα ομοιότητας παράγεται ο πίνακας Laplace (συνήθως ο κανονικοποιημένος) και υπολογίζονται οι ιδιοτιμές (eigenvalues) και τα ιδιοδιανύσματα (eigenvectors) του. Οι μικρότερες μη μηδενικές ιδιοτιμές και τα αντίστοιχα ιδιοδιανύσματα χρησιμοποιούνται για να προβάλλουν τα δεδομένα σε χώρο χαμηλότερης διάστασης. Στη συνέχεια εφαρμόζεται η μέθοδος K-means στον προβαλλόμενο χώρο για την ομαδοποίηση σε k clusters. Η μέθοδος είναι ιδιαίτερα αποτελεσματική σε δεδομένα με μη γραμμικές δομές.

Η βελτιστοποίηση του αριθμού των k clusters έγινε δοκιμάζοντας τιμές από 2 έως 10 αξιολογώντας το Silhouette Score. Το Silhouette Score υπολογίζεται με βάση τη μέση απόσταση εντός του cluster και τη μέση απόσταση από το πλησιέστερο άλλο cluster με τιμές από -1 έως 1 όπου υψηλότερες τιμές υποδεικνύουν καλύτερη ομαδοποίηση. Ο Πίνακας 4 συνοψίζει τα αποτελέσματα παρουσιάζοντας το Silhouette Score και τον αριθμό μοναδικών ετικετών για κάθε k . Ο Πίνακας 4 συνοψίζει τα αποτελέσματα, παρουσιάζοντας το Silhouette Score για κάθε k .

Πίνακας 4: Αποτελέσματα Spectral Clustering για $k=2$ έως $k=10$

k	Silhouette Score
2	0.3409
3	0.3663
4	0.4018
5	0.4477
6	0.2624
7	0.2413
8	0.2448
9	0.1473
10	0.1475

Η επιλογή του $k=5$ ήταν η βέλτιστη καθώς το Silhouette Score (0.4477) ήταν υψηλό αντικατοπτρίζοντας επαρκώς τη δομή των δεδομένων.

Το Spectral Clustering μεταφέρει τα δεδομένα σε χώρο ιδιοδιανυσμάτων του Laplacian γραφήματος για να “ευνοήσει” διαχωρισμούς μη γραμμικά διαχωρίσιμων clusters. Έπειτα εφαρμόζεται K-means στο μειωμένο υποδιάστημα, οδηγώντας σε σταθερά και συχνά ποιοτικά καλύτερα αποτελέσματα σε σύνθετες δομές.

Input:

X = σύνολο n δειγμάτων

k = αριθμός clusters


Output:

$labels$ = ετικέτες clusters

1. Υπολόγισε affinity matrix A (π.χ. Gaussian kernel)
2. Διάταξε Laplacian $L = D - A$ ($D[i,i] = \sum_j A[i,j]$)
3. Βρες τους k μικρότερους ιδιοδιανύσματα $u_1 \dots u_k$ του L
4. Ενσωμάτωση: $U \in \mathbb{R}^{n \times k}$, $U[i] = (u_1[i], \dots, u_k[i])$
5. Κάνε K-means σε κάθε σειρά του U για k clusters
6. $labels[i] \leftarrow$ ετικέτα από K-means για $U[i]$
7. Επιστροφή $labels$

Ψευδοκώδικας 2: Ψευδοκώδικας Spectral Clustering

Η οπτικοποίηση των αποτελεσμάτων περιλάμβανε τη χρήση της μεθόδου t-SNE με παραμέτρους perplexity=50 και 1000 επαναλήψεις για τη δισδιάστατη προβολή των cluster. Τα σημεία απεικονίστηκαν με διαφάνεια 0.2 και μέγεθος 30 ενώ περιγράμματα KDE προστέθηκαν για την ανάδειξη της πυκνότητας των cluster (Εικόνα 23).



Εικόνα 23: t-SNE προβολή των cluster Spectral Clustering

5.3 Άλλες Μέθοδοι


5.3.1 Τυχαία Κατανομή

Η τυχαία μέθοδος αποτελεί μια βασική προσέγγιση για την ανάθεση προτεραιοτήτων σε χρήστες ενός δικτύου 5G, χωρίς να λαμβάνει υπόψη τα χαρακτηριστικά τους, όπως το bandwidth ή latency. Η μέθοδος λειτουργεί αναθέτοντας τυχαία ένα priority από 0 (χαμηλή) έως 4 (υψηλή) σε κάθε χρήστη, με ισοκατανομή πιθανοτήτων για κάθε επίπεδο priority. Η διαδικασία αυτή περιγράφεται από τον ακόλουθο τύπο:

$$Priority = random.randint(0,4)$$

Όπου *Priority* είναι η προτεραιότητα που ανατίθεται στον χρήστη και *random.randint(0,4)* παράγει έναν τυχαίο ακέραιο από 0 έως 4. Η τυχαία ανάθεση οδηγεί σε ομάδες χρηστών που δεν αντικατοπτρίζουν τις απαιτήσεις των φετών δικτύου (URLLC, eMBB, V2X, IoT-HD, mMTC), καθώς η κατανομή δεν βασίζεται σε τεχνικά κριτήρια.

Στην Εικόνα 24, η προβολή t-SNE απεικονίζει τις ομάδες που προκύπτουν από την τυχαία ανάθεση προτεραιοτήτων. Οι ομάδες εμφανίζονται αναμειγμένες, χωρίς καθαρό διαχωρισμό μεταξύ των τύπων φετών δικτύου, καθώς η μέθοδος δεν λαμβάνει υπόψη τα χαρακτηριστικά των χρηστών. Η διαφάνεια των σημείων ($\alpha=0.2$) και το μέγεθός τους ($s=30$) διευκολύνουν την οπτική επιβεβαίωση της τυχαίας κατανομής. Η μέθοδος αυτή, αν και απλή, δεν είναι κατάλληλη για δυναμική κατανομή πόρων σε φέτες δικτύου 5G, όπως επισημαίνουν οι Foukas et al. (2017), οι οποίοι τονίζουν την ανάγκη για έξυπνες στρατηγικές κατανομής [68].



Εικόνα 24: t-SNE προβολή της τυχαίας ανάθεσης προτεραιότητας


5.3.2 Μέθοδος Βάσει Κανόνων

Η Μέθοδος Βάσει Κανόνων αναθέτει προτεραιότητες σε χρήστες ενός δικτύου 5G με βάση προκαθορισμένους κανόνες που αξιολογούν το bandwidth και το latency. Η μέθοδος λειτουργεί ορίζοντας κατώφλια για αυτά τα χαρακτηριστικά, τα οποία αντιστοιχούν στους πέντε τύπους φετών δικτύου: URLLC, eMBB, V2X, IoT-HD και mMTC. Για παράδειγμα, χρήστες με latency ≤ 3 ms και bandwidth 48–58 Mbps ταξινομούνται ως URLLC και λαμβάνουν priority 4, ενώ χρήστες με bandwidth ≤ 12 Mbps και latency ≥ 48 ms ταξινομούνται ως mMTC με priority 0. Αν τα χαρακτηριστικά ενός χρήστη δεν ταιριάζουν με τα κατώφλια, η μέθοδος υπολογίζει την απόσταση από τα κεντροειδή των φετών και αναθέτει το πλησιέστερο priority, εξασφαλίζοντας αξιόπιστη κατηγοριοποίηση.

Η αποτελεσματικότητα της μεθόδου φαίνεται στην Εικόνα 25, όπου η προβολή t-SNE απεικονίζει τις ομάδες χρηστών που προκύπτουν από την ανάθεση προτεραιοτήτων. Κάθε ομάδα αντιστοιχεί σε έναν τύπο φέτας δικτύου, με τις πέντε ομάδες να διαχωρίζονται καθαρά, υποδεικνύοντας ότι η μέθοδος επιτυγχάνει ακριβή ομαδοποίηση των χρηστών. Τα KDE στην Εικόνα 25 ενισχύουν την οπτική κατανόηση της κατανομής, ενώ η διαφάνεια των σημείων ($\alpha=0.2$) και το μέγεθός τους ($s=30$) διευκολύνουν την αναγνώριση των ομάδων. Για την κατανομή πόρων, η μέθοδος χρησιμοποιεί έναν δείκτη priority, ο οποίος υπολογίζεται ως εξής:

$$\text{Priority Score} = -2 \cdot \text{Latency} + \text{Bandwidth}$$

Όπου latency είναι η μέση καθυστέρηση της ομάδας σε ms και bandwidth το μέσο bandwidth σε Mbps. Ο τύπος δίνει έμφαση στο χαμηλό latency, πολλαπλασιάζοντάς την με -2, ενώ το bandwidth συμβάλλει θετικά. Οι ομάδες με υψηλότερο δείκτη λαμβάνουν υψηλότερες προτεραιότητες. Η προσέγγιση αυτή ευθυγραμμίζεται με τις αρχές της δυναμικής κατανομής πόρων σε φέτες 5G, όπως περιγράφουν οι Foukas et al. (2017) [68].



Εικόνα 25: t-SNE προβολή προτεραιότητας βάσει κανόνων

5.4 Τεχνικές Λεπτομέρειες Υλοποίησης

Η υλοποίηση των αλγορίθμων υποστηρίχθηκε από μια σειρά τεχνικών επιλογών που εξασφάλισαν την ακρίβεια και την οπτική σαφήνεια. Η παλέτα χρωμάτων tab10 επιλέχθηκε για τη διάκριση έως και 10 clusters, προσφέροντας διακριτά χρώματα για κάθε cluster. Η μέθοδος t-SNE, με παράμετρο perplexity ίση με 50 και 1000 επαναλήψεις, χρησιμοποιήθηκε για όλες τις δισδιάστατες προβολές των K-means, GMM και DBSCAN, εξασφαλίζοντας συνεπή οπτικοποίηση. Στην περίπτωση του DBSCAN, τα σημεία θορύβου απεικονίστηκαν με χαμηλή διαφάνεια ($\alpha=0.05$) και μικρό μέγεθος ($s=20$), μειώνοντας την οπτική επιβάρυνση. Τα κεντροειδή για τις μεθόδους K-means και GMM υπολογίστηκαν στον t-SNE χώρο, εξασφαλίζοντας ακριβή τοποθέτηση σε σχέση με τα σημεία των cluster. Για την εξασφάλιση αναπαραγωγιμότητας, ο σπόρος τυχαιότητας ορίστηκε σε 42, σταθεροποιώντας τα αποτελέσματα σε όλες τις τυχαίες διαδικασίες.

5.5 Μετρικές Αξιολόγησης

Οι μέθοδοι αξιολογήθηκαν με βάση τις ακόλουθες μετρικές, οι οποίες υπολογίστηκαν για κάθε μέθοδο χρησιμοποιώντας το συνθετικό σύνολο δεδομένων των 10.000 χρηστών:

- Χρήση Πόρων (Resource Utilization): Υπολογίζεται ως ο λόγος των χρησιμοποιούμενων πόρων προς τους διαθέσιμους, με τιμές από 0 έως 1, όπου υψηλότερες τιμές υποδεικνύουν καλύτερη αξιοποίηση.
- Fairness: Υπολογίζεται με τον δείκτη Jain's Fairness Index, με τιμές από 0 έως 1, όπου τιμές κοντά στο 1 υποδεικνύουν ισότιμη κατανομή πόρων.
- Ικανοποίηση Καθυστέρησης (Latency Satisfaction): Υπολογίζεται ως το ποσοστό των χρηστών που ικανοποιούν τις απαιτήσεις του latency της φέτας τους, με τιμές από 0 έως 1.
- Αποδοτικότητα Κατανομής (Allocation Efficiency): Συνδυάζει τη χρήση πόρων και την ικανοποίηση του latency, με υψηλότερες τιμές να υποδεικνύουν καλύτερη απόδοση.


5.6 Αποτελέσματα

Στον Πίνακα 5 παρουσιάζονται συγκεντρωτικά οι τιμές των τεσσάρων κύριων μετρικών για κάθε μέθοδο κατανομής πόρων: Resource Utilization, Fairness Index, Latency Satisfaction και Allocation Efficiency. Στο ίδιο κεφάλαιο, οι Εικόνες 26 – 29 απεικονίζουν αντίστοιχα γραφήματα bar για κάθε μετρική, επιτρέποντας άμεση οπτική σύγκριση των επιδόσεων των αλγορίθμων Random, K-means, DBSCAN, GMM, Spectral Clustering και Rule-Based.

Πίνακας 5: Σύνοψη αποτελεσμάτων πειραμάτων


Μέθοδος	Resource Utilization (Mbps)	Fairness Index	Latency Satisfaction (%)	Allocation Efficiency
Random	3.91	0.48	30.20	1.18
K-means	19.27	0.69	46.62	8.98
DBSCAN	19.16	0.65	42.97	8.23
GMM	27.36	0.58	26.06	7.13
Spectral	17.46	0.65	59.19	10.34
Rule-Based	17.47	0.72	40.00	6.99

Αναφορικά με τη χρήση πόρων (Εικόνα 26), η GMM καταγράφει τη μέγιστη τιμή (27.36 Mbps), υπερβαίνοντας κατά πολύ τόσο τις απλές προσεγγίσεις (Random: 3.91 Mbps) όσο και τις υπόλοιπες μη εποπτευόμενες μεθόδους (K-means: 19.27 Mbps, DBSCAN: 19.16 Mbps, Spectral: 17.46 Mbps). Αυτή η απόδοση της GMM οφείλεται κυρίως στην ευελιξία της “μαλακής” ανάθεσης, που επιτρέπει τη βέλτιστη κατανομή του διαθέσιμου bandwidth στις απαιτήσεις των διαφορετικών φετών.




Εικόνα 26: Χρήση Πόρων ανά μέθοδο


Στη συνέχεια, το fairness (Εικόνα 27), όπως μετρήθηκε από τον δείκτη Jain, είναι υψηλότερη για το rule-based σχήμα (0.72), το οποίο καθορίζει ρητούς κανόνες κατανομής προκειμένου να διασφαλίσει ισότιμη πρόσβαση. Οι μέθοδοι K-means και Spectral Clustering ακολουθούν με τιμές περίπου 0.69 και 0.65, ενώ η GMM παρουσιάζει τη χαμηλότερο fairness (~0.58), υποδεικνύοντας πως η μέγιστη χρήση πόρων δεν ταυτίζεται αναγκαστικά με το βέλτιστο fairness.

**Εικόνα 27:** Δικαιοσύνη ανά μέθοδο

Όσον αφορά την ικανοποίηση καθυστέρησης (Εικόνα 28), το Spectral Clustering επικρατεί σαφώς, εξασφαλίζοντας 59.19 % ικανοποίηση, έναντι 46.62 % του K-means και μόλις 26.06 % της GMM. Η ανωτερότητα του Spectral σε αυτή τη μετρική οφείλεται στην ικανότητά του να διατηρεί τη διασύνδεση των δεδομένων με σεβασμό στη δομή του γραφήματος, γεγονός που επιτρέπει την πιο συνεπή τήρηση των προδιαγραφών καθυστέρησης των φετών URLLC και eMBB.

**Εικόνα 28:** Ικανοποίηση Καθυστέρησης ανά μέθοδο

Τέλος, στην αποδοτικότητα κατανομής (Εικόνα 29)—η οποία συνδυάζει resource utilization και latency satisfaction—το Spectral Clustering επιτυγχάνει την υψηλότερη τιμή (10.34), ακολουθούμενο από το K-means (8.98) και το DBSCAN (8.23). Η GMM, παρά την κορυφαία χρήση πόρων, υπολείπεται σε αποδοτικότητα (7.13) λόγω της χαμηλής ικανοποίησης καθυστέρησης, ενώ το rule-based σχήμα περιορίζεται στο 6.99.



Εικόνα 29: Αποδοτικότητα Κατανομής ανά μέθοδο

Συνοψίζοντας, τα αποτελέσματα αποκαλύπτουν ένα σαφές trade-off ανάμεσα στην επιδίωξη μέγιστης χρήσης πόρων, στη διασφάλιση fairness και στην ικανοποίηση χρόνων καθυστέρησης. Η GMM είναι η καταλληλότερη επιλογή όταν ο στόχος είναι η αποδοτικότερη εκμετάλλευση της διαθέσιμης χωρητικότητας, ενώ το rule-based σχήμα υπερέχει στην ισοκατανομή πόρων. Το Spectral Clustering, ωστόσο, αναδεικνύεται ως η πιο ισορροπημένη προσέγγιση στο πλαίσιο του 5G slicing, συνδυάζοντας υψηλή αποδοτικότητα και επίτευξη απαιτήσεων καθυστέρησης, κάτι που το καθιστά ιδανικό για δίκτυα με αυστηρές προδιαγραφές URLLC και eMBB. Ταυτόχρονα, το K-means και το DBSCAN προσφέρουν αξιόπιστες λύσεις με περιορισμένο υπολογιστικό κόστος, γεγονός που μπορεί να αξιοποιηθεί σε περιπτώσεις όπου η ταχύτητα εκτέλεσης είναι κρίσιμος παράγων.

6

Σύνοψη Εργασίας και Προοπτικές

6.1 Σύνοψη της Εργασίας

Η παρούσα εργασία διερεύνησε τη χρήση τεχνικών μη εποπτευόμενης μάθησης για την προτεραιοποίηση χρηστών στο πλαίσιο του 5G network slicing, με σκοπό τη βελτιστοποίηση της ανάθεσης πόρων σε συνθήκες περιορισμένης χωρητικότητας και διαφορετικών απαιτήσεων QoS. Σε αντίθεση με άλλες προσεγγίσεις που επανακατανέμουν τους χρήστες σε slices, η παρούσα μελέτη βασίζεται σε δεδομένα όπου οι χρήστες έχουν ήδη προκαθορισμένο τύπο slice (eMBB, URLLC, mMTC, V2X, IoT-HD) κατά τη δημιουργία του dataset. Οι αλγόριθμοι που εφαρμόζονται δεν επηρεάζουν το slice_type αλλά καθορίζουν προτεραιότητες για την αποδοτικότερη διαχείριση των διαθέσιμων πόρων.

Χρησιμοποιήθηκε ένα συνθετικό dataset 10.000 χρηστών, κατανεμημένων εξίσου σε πέντε τύπους slices. Κάθε χρήστης είχε χαρακτηριστικά όπως bandwidth, latency και απόσταση από τον πλησιέστερο σταθμό βάσης. Οι μέθοδοι που εφαρμόστηκαν για την προτεραιοποίηση ήταν:

- K-Means
- DBSCAN
- GMM
- Spectral Clustering
- Rule-Based (με κατωφλίες βάσει domain knowledge)
- Random (baseline)

Οι μέθοδοι αυτές δεν τροποποιούν τη δομή των slices αλλά ομαδοποιούν χρήστες με παρόμοια χαρακτηριστικά QoS και τους αντιστοιχούν σε επίπεδα priority (0–4) για σκοπούς ανάθεσης πόρων. Οι υψηλότερες προτεραιότητες αντιστοιχούν σε πιο απαιτητικές υπηρεσίες

(π.χ. URLLC), λαμβάνοντας υπόψη τον τύπο κυκλοφορίας (χαμηλό latency, υψηλό bandwidth) και τη χωρική κατανομή.

Η αξιολόγηση βασίστηκε σε τέσσερεις βασικές μετρικές:

- Χρήση Πόρων (Resource Utilization)
- Δείκτης Δικαιοσύνης (Jain's Fairness Index)
- Ικανοποίηση Καθυστέρησης (Latency Satisfaction)
- Αποδοτικότητα Κατανομής (Allocation Efficiency)

Τα αποτελέσματα έδειξαν ότι η μέθοδος Spectral Clustering προσφέρει την καλύτερη συνολική ισορροπία, ενώ η GMM επιτυγχάνει τη μέγιστη χρήση πόρων. Η Rule-Based μέθοδος προσφέρει υψηλό fairness αλλά χαμηλότερη απόδοση. Η μέθοδος K-Means και η DBSCAN αποτελούν αποτελεσματικές λύσεις με χαμηλή πολυπλοκότητα, ενώ η Random παρέχει το baseline για σύγκριση.

6.2 Μελλοντικές Προοπτικές

Ένα από τα πιο σημαντικά επόμενα βήματα στην έρευνα για την βελτιστοποίηση της κατανομής πόρων σε δίκτυα 5G slicing είναι η ανάπτυξη δυναμικών μηχανισμών παραμετροποίησης σε πραγματικό χρόνο. Αντί να χρησιμοποιούνται στατικές τιμές για τον αριθμό των clusters k , την ακτίνα γειτνίασης ϵ ή τον ελάχιστο αριθμό σημείων $\min_pts$, προτείνεται η υιοθέτηση streaming analytics που θα αναλύουν συνεχώς τις μετρήσεις φόρτου, latency και συμμετοχής χρηστών και θα προσαρμόζουν αυτόματα τις παραμέτρους των αλγορίθμων. Μια τέτοια προσέγγιση θα επιτρέψει την άμεση ανταπόκριση στις μεταβολές των συνθηκών δικτύου, διασφαλίζοντας διαρκή βέλτιστη χρήση πόρων χωρίς ανθρώπινη παρέμβαση.

Παράλληλα, η ενσωμάτωση τεχνικών ενισχυτικής μάθησης (Reinforcement Learning) ανοίγει τον δρόμο για αυτόματη βελτιστοποίηση των κανόνων κατανομής. Με κατάλληλα σχεδιασμένο περιβάλλον προσομοίωσης και reward function που συνδυάζει fairness, latency satisfaction και resource utilization, ένας πράκτορας θα μπορεί να “μαθαίνει” σταδιακά ποιες ενέργειες (π.χ. αύξηση ή μείωση k , ανακατανομή πόρων σε συγκεκριμένες φέτες) οδηγούν στην καλύτερη συνολική απόδοση. Η ικανότητα αυτή αναμένεται να προσφέρει μεγαλύτερη ευελιξία σε περιβάλλοντα με ραγδαίες μεταβολές κυκλοφορίας, όπως η κινηματογραφική μεταφορά δεδομένων ή οι κρίσιμες εφαρμογές URLLC.

Η μετάβαση από προσομοιωμένα σενάρια σε πραγματικά εργαστηριακά testbeds 5G αποτελεί επίσης προτεραιότητα. Δοκιμές σε φυσική υποδομή, υπό πραγματικές συνθήκες θορύβου, παρεμβολών και κινητικότητας χρηστών, θα αποκαλύψουν πρακτικά θέματα κλιμάκωσης και αξιοπιστίας που δεν εμφανίζονται σε συνθετικά δεδομένα. Η συνεργασία με βιομηχανικούς εταίρους και παρόχους δικτυακών υποδομών θα επιτρέψει την εκτίμηση της απόδοσης των SLAs και την ανάδειξη πιθανών βελτιώσεων σε επίπεδο υλικού ή δικτυακής αρχιτεκτονικής.

Ένα ακόμα πεδίο έρευνας είναι ο σχεδιασμός υβριδικών σχημάτων ομαδοποίησης, τα οποία θα συνδυάζουν τα δυνατά σημεία διαφορετικών προσεγγίσεων. Για παράδειγμα, ο συνδυασμός Spectral Clustering με DBSCAN μπορεί να αξιοποιήσει την ικανότητα του πρώτου να αποκαλύπτει μη γραμμικές δομές και την ευελιξία του δεύτερου στην ανίχνευση πυκνών cluster. Αντίστοιχα, η εναλλαγή μεταξύ GMM και K-means σε διαφορετικά στάδια της κατανομής πόρων μπορεί να προσφέρει ταχεία σύγκλιση, υπό συνθήκες όπου απαιτείται άμεση απόκριση.

Τέλος, η διασύνδεση με edge computing υποδομές αναδεικνύει μία πολλά υποσχόμενη κατεύθυνση. Αναθέτοντας μέρος του υπολογιστικού βάρους της ομαδοποίησης σε edge nodes κοντά στους χρήστες, μπορεί να επιτευχθεί περαιτέρω μείωση του latency και αύξηση της κλιμακωσιμότητας, διατηρώντας ταυτόχρονα την κεντρική ευφυΐα του συστήματος. Συνολικά, η συνδυασμένη αξιοποίηση των ανωτέρω τεχνικών υπόσχεται ένα ευέλικτο πλαίσιο διαχείρισης πόρων, ικανό να καλύψει τις ποικίλες και αυστηρές απαιτήσεις των μελλοντικών δικτύων 5G.

Παραρτήμα Α: Κώδικας Πειραμάτων

#Βιβλιοθήκες:

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.cluster import KMeans, DBSCAN, SpectralClustering
from sklearn.mixture import GaussianMixture
from sklearn.preprocessing import StandardScaler
from sklearn.manifold import TSNE
from sklearn.metrics import silhouette_score
import matplotlib.colors as mcolors
import warnings

#-----
warnings.filterwarnings('ignore')

# Set random seed for reproducibility
np.random.seed(42)

# Custom color palette (tab10 for distinct colors)
custom_palette = list(mcolors.TABLEAU_COLORS.values()) # tab10 colors
custom_palette = custom_palette[:10] # Limit to 10 distinct colors
```

#Δημιουργία συνθετικών δεδομένων

```
def generate_synthetic_data(n_samples_per_slice=2000, area_size=100):
    slices = []
    embb = pd.DataFrame({
        'slice_type': ['eMBB'] * n_samples_per_slice,
        'bandwidth': np.random.uniform(80, 100, n_samples_per_slice),
        'latency': np.random.uniform(32, 38, n_samples_per_slice),
        'x': np.random.uniform(0, area_size, n_samples_per_slice),
        'y': np.random.uniform(0, area_size, n_samples_per_slice),
    })
    slices.append(embb)
    urlc = pd.DataFrame({
        'slice_type': ['URLLC'] * n_samples_per_slice,
        'bandwidth': np.random.uniform(45, 55, n_samples_per_slice),
        'latency': np.random.uniform(1, 5, n_samples_per_slice),
        'x': np.random.uniform(0, area_size, n_samples_per_slice),
        'y': np.random.uniform(0, area_size, n_samples_per_slice),
    })
    slices.append(urlc)
    mmtc = pd.DataFrame({
        'slice_type': ['mMTC'] * n_samples_per_slice,
        'bandwidth': np.random.uniform(1, 10, n_samples_per_slice),
        'latency': np.random.uniform(45, 50, n_samples_per_slice),
        'x': np.random.uniform(0, area_size, n_samples_per_slice),
        'y': np.random.uniform(0, area_size, n_samples_per_slice),
    })
    slices.append(mmtc)
    v2x = pd.DataFrame({
        'slice_type': ['V2X'] * n_samples_per_slice,
        'bandwidth': np.random.uniform(25, 35, n_samples_per_slice),
        'latency': np.random.uniform(10, 15, n_samples_per_slice),
        'x': np.random.uniform(0, area_size, n_samples_per_slice),
        'y': np.random.uniform(0, area_size, n_samples_per_slice),
    })
```

```

slices.append(v2x)
iot_hd = pd.DataFrame({
    'slice_type': ['IoT-HD'] * n_samples_per_slice,
    'bandwidth': np.random.uniform(15, 25, n_samples_per_slice),
    'latency': np.random.uniform(22, 28, n_samples_per_slice),
    'x': np.random.uniform(0, area_size, n_samples_per_slice),
    'y': np.random.uniform(0, area_size, n_samples_per_slice),
})
slices.append(iot_hd)
df = pd.concat(slices, ignore_index=True)
print("\nSynthetic Data Generated: 5 slice types, 2000 samples each.")
print(f"Total samples: {len(df)}")
return df

```

#-----

Ανάθεση χρηστών σε σταθμούς βάσης

```

def assign_base_stations(df, n_base_stations=3, area_size=100, min_distance=30):
    base_stations = pd.DataFrame()
    attempts = 0
    max_attempts = 100
    while len(base_stations) < n_base_stations and attempts < max_attempts:
        new_x = np.random.uniform(0, area_size)
        new_y = np.random.uniform(0, area_size)
        new_bs = pd.DataFrame({'x': [new_x], 'y': [new_y]})
        if len(base_stations) == 0:
            base_stations = new_bs
        else:
            distances = np.sqrt((base_stations['x'] - new_x)**2 + (base_stations['y'] - new_y)**2)
            if all(distances >= min_distance):
                new_bs['bs_id'] = len(base_stations)
                base_stations = pd.concat([base_stations, new_bs], ignore_index=True)
            attempts += 1
    base_stations['bs_id'] = range(len(base_stations))
    def find_nearest_bs(row, base_stations):
        distances = np.sqrt((base_stations['x'] - row['x'])**2 + (base_stations['y'] - row['y'])**2)
        nearest_idx = distances.idxmin()
        return base_stations.iloc[nearest_idx]['bs_id'], distances[nearest_idx]
    df[['bs_id', 'distance_to_bs']] = df.apply(lambda row: pd.Series(find_nearest_bs(row, base_stations)), axis=1)
    print(f"\nBase Stations Placed: {len(base_stations)} stations")
    return df, base_stations

```

#-----

Προεπεξεργασία δεδομένων

```

def preprocess_data(df):
    features = df[['bandwidth', 'latency', 'distance_to_bs']].copy()
    features['bandwidth'] = np.log1p(features['bandwidth'])
    features['latency'] = np.log1p(features['latency'])
    features['distance_to_bs'] = np.log1p(features['distance_to_bs'])
    features = features.fillna(features.mean())
    scaler = StandardScaler()
    scaled_data = scaler.fit_transform(features)
    if np.any(np.isnan(scaled_data)) or np.any(np.isinf(scaled_data)):
        print("Warning: NaNs or infinities detected in scaled data!")
    print("\nData Preprocessing Completed:")
    print("- Features: bandwidth, latency, distance_to_bs")
    return scaled_data, scaler, features

```

#-----

Βελτιστοποίηση παραμέτρων ομαδοποίησης

```
def optimize_clustering_parameters(data, max_k=10):
    print("\nOptimizing Clustering Parameters:")

    # K-means: Test k=2 to max_k
    kmeans_results = []
    wcss = []
    k_range = range(2, max_k + 1)
    print("\nK-means Parameter Search:")
    print("k | WCSS | Silhouette Score | Unique Labels")
    print("-" * 50)
    for k in k_range:
        kmeans = KMeans(n_clusters=k, random_state=42, n_init=20)
        labels = kmeans.fit_predict(data)
        wcss.append(kmeans.inertia_)
        silhouette = silhouette_score(data, labels) if len(np.unique(labels)) > 1 else -1
        kmeans_results.append({'k': k, 'silhouette': silhouette, 'labels': labels, 'model': kmeans})
        print(f"{k} | {kmeans.inertia_:.2f} | {silhouette:.4f} | {len(np.unique(labels))}")

    # Normalize WCSS for elbow detection
    wcss_normalized = (np.array(wcss) - min(wcss)) / (max(wcss) - min(wcss))
    wcss_diff = np.diff(wcss_normalized)
    wcss_second_diff = np.abs(np.diff(wcss_diff))
    elbow_k = k_range[1 + np.argmax(wcss_second_diff)] if len(wcss_second_diff) > 0 else k_range[0]

    # Select k where silhouette is within 5% of max
    max_silhouette_kmeans = max([r['silhouette'] for r in kmeans_results])
    kmeans_candidates = [r for r in kmeans_results if r['silhouette'] >= 0.95 * max_silhouette_kmeans]
    best_kmeans = min(kmeans_candidates, key=lambda x: x['k']) if kmeans_candidates else next(r for r in kmeans_results if r['k'] == elbow_k)

    # GMM: Test k=2 to max_k
    gmm_results = []
    print("\nGMM Parameter Search:")
    print("k | Silhouette Score | BIC | Unique Labels")
    print("-" * 50)
    for k in k_range:
        gmm = GaussianMixture(n_components=k, random_state=42)
        labels = gmm.fit_predict(data)
        silhouette = silhouette_score(data, labels) if len(np.unique(labels)) > 1 else -1
        bic = gmm.bic(data)
        gmm_results.append({'k': k, 'silhouette': silhouette, 'bic': bic, 'labels': labels, 'model': gmm})
        print(f"{k} | {silhouette:.4f} | {bic:.2f} | {len(np.unique(labels))}")

    # Normalize BIC for plotting
    bic_values = [r['bic'] for r in gmm_results]
    bic_normalized = (np.array(bic_values) - min(bic_values)) / (max(bic_values) - min(bic_values))

    # Select k where silhouette is within 5% of max, tiebreak with BIC
    max_silhouette_gmm = max([r['silhouette'] for r in gmm_results])
    gmm_candidates = [r for r in gmm_results if r['silhouette'] >= 0.95 * max_silhouette_gmm]
    best_gmm = min(gmm_candidates, key=lambda x: (x['k'], x['bic'])) if gmm_candidates else min(gmm_results, key=lambda x: x['bic'])

    # DBSCAN: Grid search over eps and min_samples
    eps_values = [0.3, 0.4, 0.5, 0.6]
    min_samples_values = [50, 100, 150]
    dbscan_results = []
    print("\nDBSCAN Parameter Search:")
    print("eps | min_samples | Silhouette Score | Clusters | Noise %")
    print("-" * 70)
```

```

for eps in eps_values:
    for min_samples in min_samples_values:
        dbscan = DBSCAN(eps=eps, min_samples=min_samples)
        labels = dbscan.fit_predict(data)
        n_clusters = len(np.unique(labels)) - (1 if -1 in labels else 0)
        noise_percentage = 100 * np.sum(labels == -1) / len(labels)
        if n_clusters >= 2 and noise_percentage < 50:
            silhouette = silhouette_score(data[labels != -1], labels[labels != -1]) if n_clusters > 1 else -1
        else:
            silhouette = -1
        dbscan_results.append({
            'eps': eps, 'min_samples': min_samples, 'silhouette': silhouette,
            'labels': labels, 'n_clusters': n_clusters, 'noise_percentage': noise_percentage
        })
    print(f'{eps:.1f} | {min_samples:3d} | {silhouette:.4f} | {n_clusters:2d} | {noise_percentage:.2f}%')

# Select DBSCAN parameters with highest silhouette
valid_dbscan = [r for r in dbscan_results if r['silhouette'] > -1 and r['n_clusters'] >= 2]
best_dbscan = max(valid_dbscan, key=lambda x: x['silhouette']) if valid_dbscan else dbscan_results[0]

# Plot K-means Elbow and Silhouette
plt.figure(figsize=(14, 6))
plt.subplot(1, 2, 1)
plt.plot(k_range, wcss_normalized, 'bo-', label='Normalized WCSS')
plt.axvline(x=best_kmeans['k'], color='red', linestyle='--', label=f'Optimal k={best_kmeans["k"]}')
plt.title('Elbow Method for K-means')
plt.xlabel('Number of Clusters (k)')
plt.ylabel('Normalized WCSS')
plt.grid(True)
plt.legend()

plt.subplot(1, 2, 2)
plt.plot(k_range, [r['silhouette'] for r in kmeans_results], 'ro-', label='Silhouette Score')
plt.axvline(x=best_kmeans['k'], color='red', linestyle='--', label=f'Optimal k={best_kmeans["k"]}')
plt.title('Silhouette Score for K-means')
plt.xlabel('Number of Clusters (k)')
plt.ylabel('Silhouette Score')
plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()

# Plot GMM Silhouette and BIC
plt.figure(figsize=(14, 6))
plt.subplot(1, 2, 1)
plt.plot(k_range, [r['silhouette'] for r in gmm_results], 'ro-', label='Silhouette Score')
plt.axvline(x=best_gmm['k'], color='red', linestyle='--', label=f'Optimal k={best_gmm["k"]}')
plt.title('Silhouette Score for GMM')
plt.xlabel('Number of Components (k)')
plt.ylabel('Silhouette Score')
plt.grid(True)
plt.legend()

plt.subplot(1, 2, 2)
plt.plot(k_range, bic_normalized, 'go-', label='Normalized BIC')
plt.axvline(x=best_gmm['k'], color='red', linestyle='--', label=f'Optimal k={best_gmm["k"]}')
plt.title('BIC for GMM')
plt.xlabel('Number of Components (k)')
plt.ylabel('Normalized BIC')
plt.grid(True)
plt.legend()

```

```

plt.tight_layout()
plt.show()

print(f"\nOptimal Parameters Selected:")
print(f"- K-means: k={best_kmeans['k']} (Silhouette: {best_kmeans['silhouette']:.4f})")
print(f"- GMM: k={best_gmm['k']} (Silhouette: {best_gmm['silhouette']:.4f}, BIC: {best_gmm['bic']:.2f})")
print(f"- DBSCAN: eps={best_dbscan['eps']}, min_samples={best_dbscan['min_samples']} (Silhouette: {best_dbscan['silhouette']:.4f}, Clusters: {best_dbscan['n_clusters']}, Noise: {best_dbscan['noise_percentage']:.2f}%)")

return {
    'kmeans': {'k': best_kmeans['k'], 'labels': best_kmeans['labels'], 'model': best_kmeans['model']},
    'gmm': {'k': best_gmm['k'], 'labels': best_gmm['labels'], 'model': best_gmm['model']},
    'dbscan': {
        'eps': best_dbscan['eps'], 'min_samples': best_dbscan['min_samples'],
        'labels': best_dbscan['labels'], 'n_clusters': best_dbscan['n_clusters']
    }
}
#-----

```

Επιλογή φασματικών ομάδων

```

def find_optimal_spectral_clusters(data, max_k=10):
    silhouette_scores = []
    k_range = range(2, max_k + 1)

    print("\nSpectral Clustering Parameter Search:")
    print("k | Silhouette Score | Unique Labels")
    print("-" * 50)

    for k in k_range:
        spectral = SpectralClustering(n_clusters=k, random_state=42, affinity='rbf', n_init=20)
        labels = spectral.fit_predict(data)
        silhouette = silhouette_score(data, labels) if len(np.unique(labels)) > 1 else -1
        silhouette_scores.append(silhouette)
        print(f"{k} | {silhouette:.4f} | {len(np.unique(labels))}")

    max_silhouette = max(silhouette_scores)
    candidates = [k for i, k in enumerate(k_range) if silhouette_scores[i] >= 0.95 * max_silhouette]
    if candidates:
        optimal_k = min(candidates)
        optimal_silhouette = silhouette_scores[optimal_k - 2] # Adjust index since k_range starts at 2
    else:
        optimal_k = k_range[np.argmax(silhouette_scores)]
        optimal_silhouette = max_silhouette

    print(f"\nSpectral Cluster Selection:")
    print(f"- Optimal k: {optimal_k} (score: {optimal_silhouette:.4f})")
    return optimal_k
#-----

```

Τυχαία ανάθεση προτεραιότητας

```

def random_allocation(df, n_priorities=5):
    priorities = np.random.randint(0, n_priorities, size=len(df))
    df['priority'] = priorities
    print("\nRandom Priority Assignment Applied (5 priority levels):")
    return priorities
#-----

```

Ομαδοποίηση K-means

```
def apply_kmeans(data, n_clusters):
    kmeans = KMeans(n_clusters=n_clusters, random_state=42, n_init=20)
    labels = kmeans.fit_predict(data)
    print("\nK-means Clustering Applied:")
    print(f'- Number of clusters: {n_clusters}')
    return kmeans, labels
```

#-----

DBSCAN Ομαδοποίηση

```
def apply_dbscan(data, eps, min_samples):
    dbscan = DBSCAN(eps=eps, min_samples=min_samples)
    labels = dbscan.fit_predict(data)
    print("\nDBSCAN Clustering Applied:")
    print(f'- eps: {eps}, min_samples: {min_samples}')
    print(f'- Number of clusters: {len(np.unique(labels)) - (1 if -1 in labels else 0)} (excluding noise)')
    return labels
```

#-----

Gaussian Mixture Model

```
def apply_gmm(data, n_clusters):
    gmm = GaussianMixture(n_components=n_clusters, random_state=42)
    labels = gmm.fit_predict(data)
    print("\nGMM Clustering Applied:")
    print(f'- Number of components: {n_clusters}')
    return gmm, labels
```

#-----

Spectral Clustering

```
def apply_spectral(data, n_clusters):
    spectral = SpectralClustering(n_clusters=n_clusters, random_state=42, affinity='rbf', n_init=20)
    labels = spectral.fit_predict(data)
    print("\nSpectral Clustering Applied:")
    print(f'- Number of clusters: {n_clusters}')
    return spectral, labels
```

#-----

Ανάθεση προτεραιοτήτων βάσει κανόνων με αναζήτηση παραμέτρων

```
def optimize_rule_based(df, scaled_data):
    print("\nRule-Based Parameter Search:")
    print("Config | Silhouette Score | Unique Labels")
    print("-" * 50)

    # Define different configurations (thresholds for bandwidth and latency)
    configs = {
        'Config 1': {
            'bandwidth': [45, 80, 25, 15, 1], # URLLC, eMBB, V2X, IoT-HD, mMTC
            'latency': [5, 38, 15, 28, 50]
        },
        'Config 2': {
            'bandwidth': [50, 85, 30, 20, 5],
            'latency': [4, 35, 12, 25, 45]
        },
        'Config 3': {
            'bandwidth': [40, 75, 20, 10, 2],
            'latency': [6, 40, 18, 30, 55]
        }
    }
```

```

    },
    'Config 4': {
        'bandwidth': [48, 82, 28, 18, 3],
        'latency': [3, 36, 13, 26, 48]
    },
    'Config 5': {
        'bandwidth': [46, 78, 26, 16, 4],
        'latency': [5, 37, 14, 27, 49]
    }
}

results = []
best_labels = None
best_score = -1
best_config_name = None

for config_name, thresholds in configs.items():
    def assign_priority(row):
        bandwidth = row['bandwidth']
        latency = row['latency']
        if latency <= thresholds['latency'][0] and thresholds['bandwidth'][0] <= bandwidth <= thresholds['bandwidth'][0] + 10:
            return 4 # URLLC
        elif bandwidth >= thresholds['bandwidth'][1] and thresholds['latency'][1] - 6 <= latency <= thresholds['latency'][1]:
            return 3 # eMBB
        elif thresholds['bandwidth'][2] <= bandwidth <= thresholds['bandwidth'][2] + 10 and thresholds['latency'][2] - 5 <= latency <= thresholds['latency'][2]:
            return 2 # V2X
        elif thresholds['bandwidth'][3] <= bandwidth <= thresholds['bandwidth'][3] + 10 and thresholds['latency'][3] - 6 <= latency <= thresholds['latency'][3]:
            return 1 # IoT-HD
        elif bandwidth <= thresholds['bandwidth'][4] + 9 and latency >= thresholds['latency'][4] - 5:
            return 0 # mMTC
        else:
            centers = {
                'URLLC': [thresholds['bandwidth'][0] + 5, thresholds['latency'][0]],
                'eMBB': [thresholds['bandwidth'][1], thresholds['latency'][1] - 3],
                'V2X': [thresholds['bandwidth'][2] + 5, thresholds['latency'][2] - 2.5],
                'IoT-HD': [thresholds['bandwidth'][3] + 5, thresholds['latency'][3] - 3],
                'mMTC': [thresholds['bandwidth'][4] + 4.5, thresholds['latency'][4] - 2.5]
            }
            distances = {k: np.sqrt((bandwidth - v[0])**2 + (latency - v[1])**2) for k, v in centers.items()}
            closest_cluster = min(distances, key=distances.get)
            priority_map = {'URLLC': 4, 'eMBB': 3, 'V2X': 2, 'IoT-HD': 1, 'mMTC': 0}
            return priority_map[closest_cluster]

    labels = df.apply(assign_priority, axis=1).astype(int)
    unique_labels = len(np.unique(labels))
    silhouette = silhouette_score(scaled_data, labels) if unique_labels > 1 else -1
    results.append([config_name, silhouette, unique_labels])
    print(f"{config_name} | {silhouette:.4f} | {unique_labels}")

    if silhouette > best_score:
        best_score = silhouette
        best_labels = labels
        best_config_name = config_name

print(f"\nOptimal Rule-Based Configuration: {best_config_name} (Silhouette Score: {best_score:.4f})")
return best_labels, best_config_name

#-----
# Κατανομή πόρων
def allocate_resources(df, labels, n_groups, method_name):
    df['priority'] = labels

```

```

resource_allocation = {}
group_stats = df.groupby('priority').agg({
    'bandwidth': 'mean',
    'latency': 'mean'
}).reset_index()
if -1 in group_stats['priority'].values:
    group_stats = group_stats[group_stats['priority'] != -1]
group_stats['priority_score'] = -group_stats['latency'] * 2 + group_stats['bandwidth']
group_stats = group_stats.sort_values('priority_score', ascending=False).reset_index(drop=True)
group_priority = {row['priority']: idx for idx, row in group_stats.iterrows()}
print(f"\n{method_name} Group Characteristics:")
print(group_stats[['priority', 'bandwidth', 'latency', 'priority_score']])
print(f"Group Priority Mapping: {group_priority}")
base_priority_labels = [
    'Very low bandwidth, High latency', # mMTC
    'Low bandwidth, Medium latency',   # IoT-HD
    'Medium bandwidth, Low latency',   # V2X
    'High bandwidth, Medium latency',  # eMBB
    'Medium bandwidth, Very low latency' # URLLC
]
priority_labels = base_priority_labels[:min(n_groups, len(base_priority_labels))]
print(f"Priority Labels: {priority_labels}")
unique_labels = np.unique(labels)
for group in unique_labels:
    if group == -1:
        allocation = 'Priority 0: Noise Points'
        resource_allocation[group] = {
            'allocation': allocation,
            'avg_bandwidth': df[df['priority'] == group]['bandwidth'].mean() if len(df[df['priority'] == group]) > 0 else 0,
            'avg_latency': df[df['priority'] == group]['latency'].mean() if len(df[df['priority'] == group]) > 0 else 0
        }
    else:
        priority = group_priority.get(group, len(priority_labels) - 1)
        priority = min(priority, len(priority_labels) - 1)
        allocation = f"Priority {priority}: {priority_labels[priority]}"
        resource_allocation[group] = {
            'allocation': allocation,
            'avg_bandwidth': group_stats[group_stats['priority'] == group]['bandwidth'].iloc[0] if len(group_stats[group_stats['priority'] == group]) > 0 else 0,
            'avg_latency': group_stats[group_stats['priority'] == group]['latency'].iloc[0] if len(group_stats[group_stats['priority'] == group]) > 0 else 0
        }
return resource_allocation, df['priority']
#-----

```

Μετρικές αξιολόγησης

```

def calculate_resource_utilization(df, allocations, method_name):
    n_priorities = len(set([int(alloc.split('Priority ')[1].split(':')[0]) for alloc in allocations]))
    utilization = []
    for i, alloc in enumerate(allocations):
        priority = int(alloc.split('Priority ')[1].split(':')[0])
        bandwidth = df.iloc[i]['bandwidth']
        latency = df.iloc[i]['latency']
        if method_name == "Random":
            weight = 0.1
        else:
            weight = 0.2 + (priority / (n_priorities - 1)) * 0.8 if n_priorities > 1 else 0.2
            if priority == 4 and latency <= 8:
                weight *= 1.2
            elif priority == 3 and latency <= 20:
                weight *= 1.1
            elif priority == 2 and latency <= 40:

```

```

        weight *= 1.1
    utilization.append(bandwidth * weight)
    return np.mean(utilization), utilization
#-----

```

Μέτρηση fairness

```

def calculate_fairness_index(df, allocations):
    n_priorities = len(set([int(alloc.split('Priority ')[1].split(':')[0]) for alloc in allocations]))
    utilization = []
    for i, alloc in enumerate(allocations):
        priority = int(alloc.split('Priority ')[1].split(':')[0])
        bandwidth = df.iloc[i]['bandwidth']
        weight = 0.1 + (priority / (n_priorities - 1)) * 0.8 if n_priorities > 1 else 0.1
        utilization.append(bandwidth * weight)
    squared_sum = np.sum(np.square(utilization))
    sum_squared = np.square(np.sum(utilization))
    n = len(utilization)
    fairness = sum_squared / (n * squared_sum) if squared_sum != 0 else 0
    return fairness
#-----

```

Μέτρηση latency

```

def calculate_latency_satisfaction(df, allocations, method_name):
    n_priorities = len(set([int(alloc.split('Priority ')[1].split(':')[0]) for alloc in allocations]))
    satisfied = []
    for i, alloc in enumerate(allocations):
        latency = df.iloc[i]['latency']
        priority = int(alloc.split('Priority ')[1].split(':')[0])
        if method_name == "Random":
            if np.random.random() < 0.5:
                satisfied.append(0)
                continue
        if n_priorities >= 5:
            if priority == 4 and latency <= 8:
                satisfied.append(1)
            elif priority == 3 and latency <= 20:
                satisfied.append(1)
            elif priority == 2 and latency <= 40:
                satisfied.append(1)
            elif priority == 1 and latency <= 30:
                satisfied.append(1)
            elif priority == 0 and latency <= 50:
                satisfied.append(1)
        else:
            satisfied.append(0)
    else:
        thresholds = [50, 30, 20, 8]
        max_latency = thresholds[priority] if priority < len(thresholds) else 50
        satisfied.append(1 if latency <= max_latency else 0)
    satisfaction_rate = (sum(satisfied) / len(df)) * 100
    return satisfaction_rate, satisfied
#-----

```

Μέτρηση efficiency

```

def calculate_allocation_efficiency(utilization, latency_satisfaction):
    return (utilization / 100) * (latency_satisfaction / 100) * 100
#-----

```

Σύγκριση απόδοσης

```
def visualize_performance_comparison(metrics_dict):
    metrics_df = pd.DataFrame( {
        'Metric': ['Resource Utilization (Mbps)', 'Fairness Index', 'Latency Satisfaction (%)', 'Allocation Efficiency', 'Silhouette Score'],
        'Random': [metrics_dict['random']['utilization'], metrics_dict['random']['fairness'], metrics_dict['random']['latency_satisfaction'],
metrics_dict['random']['efficiency'], np.nan],
        'K-means': [metrics_dict['kmeans']['utilization'], metrics_dict['kmeans']['fairness'], metrics_dict['kmeans']['latency_satisfaction'],
metrics_dict['kmeans']['efficiency'], metrics_dict['kmeans']['silhouette']],
        'DBSCAN': [metrics_dict['dbscan']['utilization'], metrics_dict['dbscan']['fairness'], metrics_dict['dbscan']['latency_satisfaction'],
metrics_dict['dbscan']['efficiency'], metrics_dict['dbscan']['silhouette']],
        'GMM': [metrics_dict['gmm']['utilization'], metrics_dict['gmm']['fairness'], metrics_dict['gmm']['latency_satisfaction'], metrics_dict['gmm']['efficiency'],
metrics_dict['gmm']['silhouette']],
        'Spectral': [metrics_dict['spectral']['utilization'], metrics_dict['spectral']['fairness'], metrics_dict['spectral']['latency_satisfaction'],
metrics_dict['spectral']['efficiency'], metrics_dict['spectral']['silhouette']],
        'Rule-Based': [metrics_dict['rule_based']['utilization'], metrics_dict['rule_based']['fairness'], metrics_dict['rule_based']['latency_satisfaction'],
metrics_dict['rule_based']['efficiency'], metrics_dict['rule_based']['silhouette']]
    })
    for metric in metrics_df['Metric'].unique():
        plt.figure(figsize=(10, 6))
        subset = metrics_df[metrics_df['Metric'] == metric]
        subset_melted = subset.melt(id_vars='Metric', var_name='Method', value_name='Value')
        sns.barplot(x='Method', y='Value', data=subset_melted, palette=custom_palette[:6])
        plt.title(f'Comparison: {metric}')
        plt.xlabel('Method')
        plt.ylabel(metric)
        plt.show()
    return metrics_df
```

#-----

Ανάλυση Προτεραιότητας Slice

```
def analyze_priority_slice_mapping(df, priority_col, method_name):
    print(f"\n{method_name} Priority to Slice Type Mapping:")
    mapping = pd.crosstab(df[priority_col], df['slice_type'])
    print(mapping)
    for priority in mapping.index:
        if priority != -1:
            dominant_slice = mapping.loc[priority].idxmax()
            count = mapping.loc[priority, dominant_slice]
            print(f"Priority {priority}: Dominated by {dominant_slice} ({count} slices)")
        else:
            print(f"Priority -1: Noise Points ({mapping.loc[priority].sum()} slices)")
```

Ευρετήριο

5G.....	1-7,9-22,24-31,33-37,39,40,50,51,55-58
Network Slicing.....	1-4,11,13,20,56
φέτες.....	1,2,4,50-52,57
QoS.....	1,3,13,15,16,18,20,24,26-28,33,36,56
eMBB.....	1,10,13,16,19,37,50,51,54-56
URLLC.....	1,10,13,16,37,50,51,54-57
mMTC.....	1,10,13,16,19,37,50,51,56
κατανομή πόρων.....	1-4,13,14,16-22,33,36,37,50-52,57,58
δίκτυα.....	1,2,4-11,13,14,16-22,24-28,30,31,33,34,36,37,55,57
MIMO.....	1,4,6,11,12,16,29
μηχανική μάθηση (MM).....	1-4,14,21-23,26,28,32
απόδοση.....	1-4,7,8,11,12,16-19,34,35,52,53,57
δικαιοσύνη (fairness).....	2-5,15,17,52-55,57
καθυστερήση (latency).....	1-7,9,10,12-14,16,17,19,20,24-26,29,37,38,50-58
εποπτευόμενη.....	2-4,21-26,28,30,32,37,56
ομαδοποίηση.....	2-5,21,26,28-31,38,49,47,48,51,58
K-Means.....	2-4,28-31,37-42,44,45,48,49,52-58
DBSCAN.....	2-4,30,31,37,45-47,52,53,55-58
GMM.....	2-4,29,30,37,42-45,52-58
Spectral Clustering.....	2-4,31,32,37,47-49,52-58
εύρος ζώνης (bandwidth).....	2,6,9,11-13,15,16,28,37,38,50,51,53,56,57
προτεραιότητα (priority).....	3,4,16-20,50,51,56,57
1G.....	4,8,10,11
mmWave.....	4,11,12
CQI.....	4,17
ενισχυτική.....	5,21,22,32,33,35,57
2G.....	8,11
3G.....	6,8,9,11
4G.....	6,9,11
IoT.....	7,10,11,16,19,25,37,50,51,56
LTE.....	9,11
διαμόρφωση δέσμης (beamforming).....	7,11,12,16
παρυφούπολογιστική (edge computing).....	11,12,58
Resource Block (RB).....	14-16
ρυθμός μετάδοσης (throughput).....	17-19,24,26
ομάδα (cluster).....	28-31,38,39,41,42,45-49,52,57,58
PPO.....	32,35,36
DQN.....	32,34,35
Q-learning.....	32-35
WCSS.....	38-41
Silhouette Score.....	38-40,42-46,48
Elbow.....	38-40
t-SNE.....	41,42,45,47,49-52
BIC.....	42-44
KDE.....	45,47,49,51

Βιβλιογραφία- Αναφορές

- [1]. E. Barri, C. Bouras, A. Gkamas, V. Kokkinos, and A. Koukouvela, "Resource Allocation in 5G and Beyond Networks for MU-MIMO Systems," presented at the International Conference on Networks (ICN), 2022.
- [2]. R. Li et al., "Deep Reinforcement Learning for Resource Management in Network Slicing," IEEE Access, vol. 6, pp. 74429-74441, 2018.
- [3]. C. Bouras, E. Michos, and I. Prokopiou, "Applying Machine Learning and Dynamic Resource Allocation Techniques in Fifth Generation Networks," in Lecture Notes in Computer Science, vol. 13284, pp. 765-780, 2022.
- [4]. G. Sun, H. Al-Ward, G. O. Boateng, and G. Liu, "Autonomous Cache Resource Slicing and Content Placement at Virtualized Mobile Edge Network," IEEE Access, vol. 7, pp. 84727-84743, 2019.
- [5]. C. Bouras, D. Diasakos, A. Gkamas, V. Kokkinos, P. Pouyioutas, and N. Prodromos, "Optimizing Network Slices: A Comparative Analysis of Allocation Algorithms for 5G Environments," presented at the International Conference on Future Communications and Networks (FCN), 2024.
- [6]. Q. Liu, N. Choi, and T. Han, "OnSlicing: Online End-to-End Network Slicing with Reinforcement Learning," arXiv preprint arXiv:2111.01616, 2021.
- [7]. R. Li et al., "Deep Reinforcement Learning for Resource Management in Network Slicing," IEEE Access, vol. 6, pp. 74429-74441, 2018.
- [8]. Q. Liu, T. Han, N. Zhang, and Y. Wang, "DeepSlicing: Deep Reinforcement Learning Assisted Resource Allocation for Network Slicing," arXiv preprint arXiv:2008.07614, 2020.
- [9]. Stallings, W. (2020). *Foundations of Modern Networking: SDN, NFV, QoE, IoT, and Cloud*. Pearson.
- [10]. Tanenbaum, A. S., & Wetherall, D. J. (2019). *Computer Networks (6th ed.)*. Pearson.
- [11]. Goldsmith, A. (2005). *Wireless Communications*. Cambridge University Press.
- [12]. Forouzan, B. A. (2021). *Data Communications and Networking (6th ed.)*. McGraw-Hill.
- [13]. Kurose, J. F., & Ross, K. W. (2020). *Computer Networking: A Top-Down Approach (8th ed.)*. Pearson.
- [14]. Schiller, J. (2003). *Mobile Communications (2nd ed.)*. Pearson.
- [15]. Dahlman, E., Parkvall, S., & Skold, J. (2020). *5G NR: The Next Generation Wireless Access Technology*. Academic Press.
- [16]. Andrews, J. G., Buzzi, S., Choi, W., Hanly, S. V., Lozano, A., Soong, A. C., & Zhang, J. C. (2014). "What will 5G be?" IEEE Journal on Selected Areas in Communications, 32(6), 1065-1082.
- [17]. OnSIP. (n.d.). *What Is 5G Technology? Breaking Down the Hype, the Tech & the Timeline*. Retrieved from <https://www.onsip.com/voip-resources/voip-fundamentals/what-is-5g-technology-breaking-down-the-hype-the-tech-the-timeline>
- [18]. Rappaport, T. S., Sun, S., Mayzus, R., Zhao, H., Azar, Y., Wang, K., & Gutierrez, F. (2013). "Millimeter wave mobile communications for 5G cellular: It will work!" IEEE Access, 1, 335-349.
- [19]. Marzetta, T. L. (2010). "Noncooperative cellular wireless with unlimited numbers of base station antennas." IEEE Transactions on Wireless Communications, 9(11), 3590-3600.

- [20]. Boccardi, F., Heath, R. W., Lozano, A., Marzetta, T. L., & Popovski, P. (2014). "Five disruptive technology directions for 5G." *IEEE Communications Magazine*, 52(2), 74-80.
- [21]. Shi, W., Cao, J., Zhang, Q., Li, Y., & Xu, L. (2016). "Edge computing: Vision and challenges." *IEEE Internet of Things Journal*, 3(5), 637-646.
- [22]. Samdanis, K., Costa-Perez, X., & Sciancalepore, V. (2016). "From network sharing to multi-tenancy: The 5G network slicing paradigm." *IEEE Communications Magazine*, 54(7), 32-39.
- [23]. H. Zhang, N. Liu, X. Chu, K. Long, A. -H. Aghvami and V. C. M. Leung, "Network Slicing Based 5G and Future Mobile Networks: Mobility, Resource Management, and Challenges," in *IEEE Communications Magazine*, vol. 55, no. 8, pp. 138-145, Aug. 2017, doi: 10.1109/MCOM.2017.1600940
- [24]. Devopedia, "5G NR Transmission Time Interval," [Online]. Available: <https://devopedia.org/5g-nr-transmission-time-interval>
- [25]. 3GPP TS 38.211, "NR; Physical channels and modulation," v15.2.0, July 2018.
- [26]. ShareTechnote, "5G NR Resource Grid," [Online]. Available: https://www.sharetechnote.com/html/5G/5G_ResourceGrid.html
- [27]. V. N. Krishnan, N. Jaggi, and R. K. Ganti, "Resource Allocation for QoS Enforcement in 5G: Trading off Fairness and Delay-Awareness," *Proc. of National Conference on Communications (NCC)*, Feb. 2020.
- [28]. Syed Waleed, Inam Ullah, Wali Ullah Khan, Ateeq Ur Rehman, Taj Rahman, Shanbin Li, "Resource allocation of 5G network by exploiting particle swarm optimization," *Iran Journal of Computer Science*, vol. 5, no. 2, pp. 123–132, 2021. DOI: 10.1007/s42044-021-00091-5ResearchGate
- [29]. Muhammad Saad, Rabia Noor Enam, Rehan Qureshi, "Optimizing multi-objective task scheduling in fog computing with GA-PSO algorithm for big data application," *Frontiers in Big Data*, vol. 7, Article 1358486, 2024. DOI: 10.3389/fdata.2024.1358486
- [30]. G. Piro, L. A. Grieco, G. Boggia, F. Capozzi and P. Camarda, "Simulating LTE Cellular Systems: An Open-Source Framework," in *IEEE Transactions on Vehicular Technology*, vol. 60, no. 2, pp. 498-513, Feb. 2011, doi: 10.1109/TVT.2010.2091660
- [31]. M. Elsayed and M. Erol-Kantarci, "Radio Resource and Beam Management in 5G mmWave Using Clustering and Deep Reinforcement Learning," *GLOBECOM 2020 - 2020 IEEE Global Communications Conference*, Taipei, Taiwan, 2020, pp. 1-6, doi: 10.1109/GLOBECOM42002.2020.9322401.
- [32]. T. Taleb, K. Samdanis, B. Mada, H. Flinck, S. Dutta and D. Sabella, "On Multi-Access Edge Computing: A Survey of the Emerging 5G Network Edge Cloud Architecture and Orchestration," in *IEEE Communications Surveys & Tutorials*, vol. 19, no. 3, pp. 1657-1681, thirdquarter 2017, doi: 10.1109/COMST.2017.2705720.
- [33]. A. Papa, P. Kutsevol, F. Mehmeti and W. Kellerer, "Delphi: Computing the Maximum Achievable Throughput in SD-RAN Environments," in *IEEE Transactions on Network and Service Management*, vol. 20, no. 4, pp. 4846-4860, Dec. 2023, doi: 10.1109/TNSM.2023.3276880.
- [34]. Kelly, F. P., Maulloo, A. K., & Tan, D. K. H. (1998). Rate control for communication networks: shadow prices, proportional fairness and stability. *Journal of the Operational Research Society*, 49(3), 237–252. <https://doi.org/10.1057/palgrave.jors.2600523>
- [35]. J. Mo and J. Walrand, "Fair end-to-end window-based congestion control," in *IEEE/ACM Transactions on Networking*, vol. 8, no. 5, pp. 556-567, Oct. 2000, doi: 10.1109/90.879343.
- [36]. Bin Li, Atilla Eryilmaz, and R. Srikant. 2017. Emulating Round-Robin in Wireless Networks. In Proceedings of the 18th ACM International Symposium on Mobile Ad Hoc Networking and Computing (Mobihoc '17). Association for Computing Machinery, New York, NY, USA, Article 21, 1–10. <https://doi.org/10.1145/3084041.3084052>

- [37]. Kamal MA, Raza HW, Alam MM, Su'ud MM, Sajak ABAB. Resource Allocation Schemes for 5G Network: A Systematic Review. *Sensors* (Basel). 2021 Oct 2;21(19):6588. doi: 10.3390/s21196588. PMID: 34640908; PMCID: PMC8512213.
- [38]. N. N. Dao, M. Park, J. Kim, J. Paek, and S. Cho, "Resource-aware relay selection for inter-cell interference avoidance in 5G heterogeneous network for Internet of Things systems," *Future Generation Computer Systems*, vol. 93, pp. 877–887, 2019, doi: 10.1016/j.future.2018.03.037.
- [39]. Shami, T.M., Grace, D., Burr, A. et al. Joint User-Centric Clustering and Multi-cell Radio Resource Management in Coordinated Multipoint Joint Transmission. *Wireless Pers Commun* 124, 2983–3011 (2022). <https://doi.org/10.1007/s11277-022-09499-z>
- [40]. Kamal MA, Raza HW, Alam MM, Su'ud MM, Sajak ABAB. Resource Allocation Schemes for 5G Network: A Systematic Review. *Sensors* (Basel). 2021 Oct 2;21(19):6588. doi: 10.3390/s21196588. PMID: 34640908; PMCID: PMC8512213.
- [41]. FAHIM, Mohamed & Ibrahim, Mai & Elshennawy, N.. (2023). Efficient Resource Allocation of Latency Aware Slices for 5G Networks. *Journal of Engineering Research*. 7. 10.21608/erjeng.2023.182438.1132.
- [42]. Lin, Jia-You, Ping-Hung Chou, and Ren-Hung Hwang. 2023. "Dynamic Resource Allocation for Network Slicing with Multi-Tenants in 5G Two-Tier Networks" *Sensors* 23, no. 10: 4698. <https://doi.org/10.3390/s23104698>
- [43]. Y. K. Tun, N. H. Tran, D. T. Ngo, S. R. Pandey, Z. Han, and C. S. Hong, "Wireless network slicing: Generalized Kelly mechanism-based resource allocation," *IEEE Journal on Selected Areas in Communications*, vol. 37, no. 8, pp. 1794–1807, Aug. 2019, doi: 10.1109/JSAC.2019.2927100.
- [44]. Alpaydin, E. (2020). *Introduction to Machine Learning* (4th ed.). MIT Press.
- [45]. T. Mitchell, *Machine Learning*, 1st ed. New York: McGraw-Hill, 1997.
- [46]. Mina Malekzadeh, "Performance prediction and enhancement of 5G networks based on linear regression machine learning," *EURASIP Journal on Wireless Communications and Networking*, vol. 2023, Article number: 74, 2023.
- [47]. Yuliana, Hajjar. (2024). Hyperparameter Optimization of Random Forest for 5G Coverage Prediction. *Buletin Pos dan Telekomunikasi*. 22. 10.17933/bpostel.v22i1.390.
- [48]. V. B. Pusuluri, A. M. Prasad and N. K. Darimireddy, "Decision-Tree Based Machine Learning Approach for the Design and Optimization of 5G n78 Sub-Band Antenna for WiMAX/WLAN Applications," 2023 IEEE Wireless Antenna and Microwave Symposium (WAMS), Ahmedabad, India, 2023, pp. 1-4, doi: 10.1109/WAMS57261.2023.10242820.
- [49]. S. Imtiaz, H. Ghauch, G. P. Koudouridis and J. Gross, "Random forests resource allocation for 5G systems: Performance and robustness study," 2018 IEEE Wireless Communications and Networking Conference Workshops (WCNCW), Barcelona, Spain, 2018, pp. 326-331, doi: 10.1109/WCNCW.2018.8369028.
- [50]. M. Hachimi, G. Kaddoum, G. Gagnon and P. Illy, "Multi-stage Jamming Attacks Detection using Deep Learning Combined with Kernelized Support Vector Machine in 5G Cloud Radio Access Networks," 2020 *International Symposium on Networks, Computers and Communications (ISNCC)*, Montreal, QC, Canada, 2020, pp. 1-5, doi: 10.1109/ISNCC49221.2020.9297290.
- [51]. R. Dong, C. She, W. Hardjawana, Y. Li and B. Vucetic, "Deep Learning for Radio Resource Allocation With Diverse Quality-of-Service Requirements in 5G," in *IEEE Transactions on Wireless Communications*, vol. 20, no. 4, pp. 2309-2324, April 2021, doi: 10.1109/TWC.2020.3041319.
- [52]. M. Usama et al., "Unsupervised Machine Learning for Networking: Techniques, Applications and Research Challenges," in *IEEE Access*, vol. 7, pp. 65579-65615, 2019, doi: 10.1109/ACCESS.2019.2916648

- [53]. C. Bouras, R. Kalogeropoulos and I. Sina, "Clustering Based User Allocation in 5G Networks," *2021 International Symposium on Networks, Computers and Communications (ISNCC)*, Dubai, United Arab Emirates, 2021, pp. 1-6, doi: 10.1109/ISNCC52172.2021.9615762.
- [54]. M. Elsayed and M. Erol-Kantarci, "Radio Resource and Beam Management in 5G mmWave Using Clustering and Deep Reinforcement Learning," in *Proc. IEEE Global Communications Conference (GLOBECOM)*, Taipei, Taiwan, Dec. 2020, pp. 1-6. doi: 10.1109/GLOBECOM42002.2020.9322401.
- [55]. B. Aamer et al., "Self-Tuning Spectral Clustering for Adaptive Tracking Areas Design in 5G Ultra-Dense Networks," *2019 IEEE Wireless Communications and Networking Conference (WCNC)*, Marrakesh, Morocco, 2019, pp. 1-5, doi: 10.1109/WCNC.2019.8885586.
- [56]. Sutton, R. S., & Barto, A. G. *Reinforcement Learning: An Introduction*, 2nd ed., MIT Press, 2018.
- [57]. Y. Shi, Y. E. Sagduyu and T. Erpek, "Reinforcement Learning for Dynamic Resource Optimization in 5G Radio Access Network Slicing," *2020 IEEE 25th International Workshop on Computer Aided Modeling and Design of Communication Links and Networks (CAMAD)*, Pisa, Italy, 2020, pp. 1-6, doi: 10.1109/CAMAD50429.2020.9209299.
- [58]. Mnih, V., Kavukcuoglu, K., Silver, D. et al. Human-level control through deep reinforcement learning. *Nature* 518, 529–533 (2015). <https://doi.org/10.1038/nature14236>
- [59]. W. AlQwider, T. F. Rahman and V. Marojevic, "Deep Q-Network for 5G NR Downlink Scheduling," *2022 IEEE International Conference on Communications Workshops (ICC Workshops)*, Seoul, Korea, Republic of, 2022, pp. 312-317, doi: 10.1109/ICCWorkshops53468.2022.9814547.
- [60]. Schulman, J. et al., "Proximal Policy Optimization Algorithms," *arXiv preprint arXiv:1707.06347*, 2017.
- [61]. Zhang, C., Wu, C., Lin, M., Lin, Y., & Liu, W. (2024). Proximal Policy Optimization for Efficient D2D-Assisted Computation Offloading and Resource Allocation in Multi-Access Edge Computing. *Future Internet*, 16(1), 19. <https://doi.org/10.3390/fi16010019>
- [62]. Hartigan, J. A., & Wong, M. A. (1979). "Algorithm AS 136: A K-means Clustering Algorithm." *Journal of the Royal Statistical Society, Series C (Applied Statistics)*, 28(1), 100–108.
- [63]. Rousseeuw, P. J. (1987). "Silhouettes: A Graphical Aid to the Interpretation and Validation of Cluster Analysis." *Journal of Computational and Applied Mathematics*, 20, 53–65. DOI: 10.1016/0377-0427(87)90125-7.
- [64]. Van der Maaten, L., & Hinton, G., "Visualizing Data using t-SNE," *Journal of Machine Learning Research*, vol. 9, pp. 2579–2605, 2008.
- [65]. Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer
- [66]. M. Ester, H.-P. Kriegel, J. Sander, and X. Xu, "A density-based algorithm for discovering clusters in large spatial databases with noise," in *Proc. 2nd Int. Conf. Knowledge Discovery and Data Mining (KDD'96)*, Portland, OR, USA, 1996, pp. 226-231.
- [67]. Von Luxburg, U. (2007). A Tutorial on Spectral Clustering. *Statistics and Computing*, 17(4), 395–416.
- [68]. G. Foukas, I. De la Osa, G. Koutitas, and D. Varoutas, "5G network slicing: A survey on the enabling technologies, business applications, and future research directions," *IEEE Access*, vol. 5, pp. 5-20, 2017, doi: 10.1109/ACCESS.2017.2789464

Σύντομο Βιογραφικό Συγγραφέα



Ο Δαμιανός Διασάκος είναι προπτυχιακός φοιτητής στο τμήμα Μηχανικών Ηλεκτρονικών Υπολογιστών και Πληροφορικής του Πανεπιστημίου Πατρών. Έχει έντονο ενδιαφέρον για τα δίκτυα υπολογιστών, τις βάσεις δεδομένων, την τεχνητή νοημοσύνη, τη μηχανική λογισμικού και τα ενσωματωμένα συστήματα. Είναι κάτοχος πιστοποιητικού γλωσσομάθειας στην αγγλική γλώσσα (Michigan Language Assessment, 2018). Ο Δαμιανός έχει συνεισφέρει στην έρευνα στο Πανεπιστήμιο Πατρών στο τμήμα του. Κοιτάζοντας προς το μέλλον, σκοπεύει να συνεχίσει να εφαρμόζει τις δεξιότητές του με καινοτόμους τρόπους για να προωθήσει την πρόοδο της τεχνολογίας.