



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ

ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ

ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

**ΚΑΤΑΝΟΜΗ ΡΑΔΙΟΠΟΡΩΝ ΣΕ ΔΙΚΤΥΑ 5G ΜΕ
ΤΕΧΝΙΚΕΣ ΕΝΙΣΧΥΤΙΚΗΣ ΜΑΘΗΣΗΣ ΚΑΙ ΕΦΑΡΜΟΓΗ
ΣΤΟ ΠΡΟΓΡΑΜΜΑΤΙΣΤΙΚΟ ΠΕΡΙΒΑΛΛΟΝ ΤΟΥ
MATLAB**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Γεώργιος Α Γεωργικόπουλος

Επιβλέπων : Χρήστος Καψάλης

Καθηγητής Ε.Μ.Π

Αθήνα, Φεβρουάριος, 2025



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ

ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ

ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

**ΚΑΤΑΝΟΜΗ ΡΑΔΙΟΠΟΡΩΝ ΣΕ ΔΙΚΤΥΑ 5G ΜΕ
ΤΕΧΝΙΚΕΣ ΕΝΙΣΧΥΤΙΚΗΣ ΜΑΘΗΣΗΣ ΚΑΙ ΕΦΑΡΜΟΓΗ
ΣΤΟ ΠΡΟΓΡΑΜΜΑΤΙΣΤΙΚΟ ΠΕΡΙΒΑΛΛΟΝ ΤΟΥ
MATLAB**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Γεώργιος Α Γεωργικόπουλος

Επιβλέπων : Χρήστος Καψάλης

Καθηγητής Ε.Μ.Π

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 9^η του Ιανουαρίου 2025.

.....

Χρήστος Καψάλης

Καθηγητής Ε.Μ.Π

.....

Παναγιώτης Κωττής

Καθηγητής Ε.Μ.Π

.....

Γεώργιος Φικιώρης

Καθηγητής Ε.Μ.Π

Αθήνα, Φεβρουάριος, 2025

.....

Γεώργιος Α Γεωργικόπουλος

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

Copyright © Γεώργιος Γεωργικόπουλος 2024-2025

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

Εισαγωγικό σημείωμα

Η έλευση της τεχνολογίας 5G αντιπροσωπεύει ένα μετασχηματιστικό ορόσημο στις τηλεπικοινωνίες, επιτρέποντας υπερταχείες ταχύτητες δεδομένων, χαμηλή καθυστέρηση και εκτεταμένη συνδεσιμότητα συσκευών σε κλίμακες που υποστηρίζουν το Διαδίκτυο των Πραγμάτων (IoT) και τις έξυπνες πόλεις. Εκμεταλλευόμενα τις προηγμένες τεχνικές μηχανικής μάθησης (ML), τα δίκτυα 5G αντιμετωπίζουν κρίσιμες προκλήσεις όπως η διαχείριση του φάσματος, η βελτιστοποίηση της ποιότητας υπηρεσίας (QoS) και η ενεργειακή αποδοτικότητα. Ανάμεσα στις προσεγγίσεις ML, η Ενισχυτική Μάθηση (RL) αναδεικνύεται ως στρατηγική κλειδί, δίνοντας τη δυνατότητα στους παράγοντες να λαμβάνουν αυτόνομες αποφάσεις αλληλεπιδρώντας με δυναμικά περιβάλλοντα δικτύου.

Η παρούσα εργασία εξετάζει την εφαρμογή του αλγορίθμου Q-learning, μιας θεμελιώδους τεχνικής RL, στη βελτιστοποίηση της απόδοσης των δικτύων 5G. Μέσω προσομοιώσεων με βάση το MATLAB, η μελέτη αναπτύσσει μοντέλα κατανομής πόρων, αναλύει την αποτελεσματικότητά τους και διερευνά την προσαρμοστικότητα του Q-learning σε πραγματικό χρόνο σε σύνθετα σενάρια δικτύου. Κύρια σημεία περιλαμβάνουν την ενσωμάτωση των Διαδικασιών Απόφασης Markov (MDP) για τον καθορισμό στρατηγικών, τη δυναμική διαχείριση του φάσματος και την ενίσχυση της εμπειρίας του χρήστη. Η έρευνα αναδεικνύει επίσης τις προκλήσεις και περιορισμούς των υλοποιήσεων RL σε περιβάλλοντα 5G, προτείνοντας πιθανές προσαρμογές για πρακτικές εφαρμογές.

Τα ευρήματα υπογραμμίζουν το δυναμικό του Q-learning για την αυτόνομη διαχείριση των δικτύων, εξασφαλίζοντας υψηλή απόδοση και QoS με ελάχιστη ανθρώπινη παρέμβαση. Η εργασία αυτή συμβάλλει στο εξελισσόμενο παράδειγμα των τηλεπικοινωνιών με τεχνητή νοημοσύνη, ανοίγοντας το δρόμο για αποδοτικά, ανθεκτικά και κλιμακώσιμα συστήματα 5G.

Λέξεις κλειδιά

5G, Τηλεπικοινωνίες, Μηχανική Μάθηση, Ενισχυτική Μάθηση, Q-learning, MATLAB, Τεχνητή Νοημοσύνη

Abstract

The advent of 5G technology represents a transformative milestone in telecommunications, enabling ultra-fast data rates, low latency, and extensive device connectivity at scales that support the Internet of Things (IoT) and smart cities. Leveraging advanced machine learning (ML) techniques, 5G networks address critical challenges such as spectrum management, quality of service (QoS) optimization, and energy efficiency. Among ML approaches, Reinforcement Learning (RL) emerges as a pivotal strategy, empowering agents to make autonomous decisions by interacting with dynamic network environments.

This paper explores the application of the Q-learning algorithm, a fundamental RL technique, in optimizing 5G network performance. Through MATLAB-based simulations, the study develops resource allocation models, analyzes their effectiveness, and investigates the real-time adaptability of Q-learning in complex network scenarios. Key aspects include the integration of Markov Decision Processes (MDP) for policy formulation, dynamic spectrum management, and enhanced user experience. The research further addresses the challenges and limitations of RL implementations in 5G environments, proposing potential adaptations for practical deployments.

The findings highlight the potential of Q-learning to drive autonomous network management, ensuring high performance and QoS with minimal human intervention. This work contributes to the evolving paradigm of AI-powered telecommunications, paving the way for efficient, resilient, and scalable 5G systems.

Keywords

5G, Telecommunications, Machine Learning, Reinforcement Learning, Q-learning, MATLAB, Artificial Intelligence

Πίνακας περιεχομένων

Εισαγωγικό σημείωμα	5
Λέξεις κλειδιά	5
Abstract	6
Keywords	6
Πίνακας περιεχομένων.....	7
Πίνακας Ακρωνυμίων	11
Εικόνες.....	13
Πίνακες	14
Μηχανική Μάθηση (Machine learning)	15
Επιβλεπόμενη Μάθηση (Supervised learning).....	17
Ταξινόμηση (Classification).....	19
Παλινδρόμηση (Regression):	20
Μεροληψία (Bias)	23
Διακύμανση (Variance)	23
Το Δίλημμα Μεροληψίας-Διακύμανσης (Bias-Variance Trade-off)	24
Υπερπροσαρμογή (Overfitting).....	25
Υποπροσαρμογή (Underfitting).....	27
Μετατόπιση του Συνόλου Δεδομένων: Μια Κρίσιμη Πρόκληση στη Μηχανική Μάθηση	29
Μη Εποπτευόμενη Μάθηση (Un-supervised learning)	31
Εισαγωγή	31
Θεμελιώδεις Έννοιες	31
Τύποι Μη Εποπτευόμενης Μάθησης	32
Προκλήσεις της Μη Εποπτευόμενης Μάθησης	34
Στρατηγικές για την Αντιμετώπιση των Προκλήσεων.....	37

Ενισχυτική Μάθηση (REINFORCEMENT LEARNING)	39
Κύριες Έννοιες στην Ενισχυτική Μάθηση.....	39
Μαθηματικά Μοντέλα.....	40
Επίλυση Προβλημάτων Ενισχυτικής Μάθησης	41
Q-Learning.....	43
Παράδειγμα εφαρμογής της τεχνικής Q-learning στο προγραμματιστικό περιβάλλον του Matlab	45
Επεξήγηση κώδικα Βήμα προς Βήμα.....	49
Διευκρινήσεις	54
Αποτελέσματα προσομοίωσης	54
Συμπεράσματα	55
Δίκτυα 5G	56
Εισαγωγή.....	56
Ενίσχυση Επικοινωνίας και Συνδεσιμότητας.....	56
Ταχύτητα Δεδομένων (Data Rate).....	56
Καθυστέρηση (Latency)	57
Διασυνδεσιμότητα Συσκευών.....	57
Εφαρμογές του 5G.....	57
Υγεία.....	57
Μεταφορές.....	58
Βιομηχανία	59
Ψυχαγωγία και Μέσα Ενημέρωσης.....	59
Προκλήσεις και Σκέψεις για την Τεχνολογία 5G.....	60
Υποδομές και Κόστος.....	60
Κατανομή Φάσματος.....	60
Ασφάλεια και Ιδιωτικότητα.....	61

Ανησυχίες για την Υγεία	61
Ευρύτερες Κοινωνικές και Οικονομικές Επιπτώσεις της 5G.....	61
Οικονομική Ανάπτυξη.....	62
Ψηφιακή Ένταξη	62
Κοινωνικός Αντίκτυπος.....	62
Δομή και Συστατικά ενός Δικτύου 5G	63
1. Φάσματα	63
2. Υποδομή Δικτύου	63
3. Κεντρικό Δίκτυο	64
4. Ραδιοτεχνολογίες	64
5. Συσκευές.....	64
6. Υπολογισμός στην Άκρη	64
7. Ασφάλεια.....	65
8. Ενεργειακή Αποδοτικότητα.....	65
9. Πρότυπα και Πρωτόκολλα	65
Παράδειγμα ενός αντιπροσωπευτικού δικτύου 5G στο προγραμματιστικό περιβάλλον του matlab	65
Επεξήγηση του κώδικα.....	70
Συμπεράσματα.....	75
Αποτελέσματα κώδικα-Διαγράμματα.....	76
Η Εφαρμογή της Q-learning στα Δίκτυα 5G.....	80
1. Κατανομή Πόρων	80
2. Διαμερισμός Δικτύου	80
3. Ενεργειακή Αποδοτικότητα.....	80
4. Διαχείριση Κίνησης.....	81
5. Διαχείριση Παρεμβολών	81
6. Εξασφάλιση Ποιότητας Υπηρεσίας (QoS).....	81

7. Βελτίωση Εμπειρίας Χρήστη	81
Συστατικά Μοντέλου Ενισχυτικής Μάθησης σε ένα περιβάλλον δικτύου 5G με χρήση Μαρκοβιανών Διαδικασιών Απόφασης (MDP)	82
Εφαρμογή Ενισχυτικής Μάθησης	83
Παράδειγμα Εφαρμογής	84
Εφαρμογές της τεχνικής Q-Learning σε δίκτυα 5G με την βοήθεια του matlab	85
Παράδειγμα 1 εφαρμογής q-learning αλγορίθμου σε ένα δίκτυο 5G	85
Χρήση του Q-learning στον Αλγόριθμο	94
Βήματα του αλγορίθμου	94
Αποτελέσματα Προσμείωσης	99
Επεξήγηση αποτελεσμάτων	100
Διαγράμματα και Συμπεράσματα	102
Παράδειγμα 2 εφαρμογής q-learning αλγορίθμου σε ένα δίκτυο 5G	106
Ανάλυση και επεξήγηση του κώδικα	111
Αποτελέσματα Προσομοίωσης	114
Ανάλυση Αποτελεσμάτων - Θεωρία	121
Ερμηνεία των Αποτελεσμάτων - Συμπεράσματα	122
Συμπεράσματα	124
Βιβλιογραφία	126

Πίνακας Ακρωνυμίων

Ακρωνύμιο	Περιγραφή
ML	Machine Learning (Μηχανική Μάθηση)
MDP	Markov Decision Process (Διαδικασία Μαρκοβιανής Απόφασης)
Q-Learning	Αλγόριθμος Μάθησης Q
PCA	Principal Component Analysis (Ανάλυση Κύριων Συνιστωσών)
DQN	Deep Q-Network (Δίκτυο Βαθιάς Μάθησης Q)
RL	Reinforcement Learning (Ενισχυτική Μάθηση)
UE	User Equipment (Συσκευή Χρήστη)
DBSCAN	Density-Based Spatial Clustering of Applications with Noise
MSE	Mean Squared Error (Μέση Τετραγωνική Απόκλιση)
OLS	Ordinary Least Squares (Μέθοδος Ελαχίστων Τετραγώνων)
QoS	Quality of Service (Ποιότητα Υπηρεσίας)
SVM	Support Vector Machine (Μηχανή Υποστήριξης Διανυσμάτων)
t-SNE	t-Distributed Stochastic Neighbor Embedding
SNR	Signal-to-Noise Ratio (Λόγος Σήματος προς Θόρυβο)
OFDM	Orthogonal Frequency-Division Multiplexing
MIMO	Multiple Input, Multiple Output
FFT	Fast Fourier Transform

dB	Decibel (Μονάδα Μέτρησης Έντασης Σήματος)
3GPP	3rd Generation Partnership Project (Πρωτόκολλα 5G)
mmWave	Millimeter Wave
Tx/Rx	Transmission/Reception (Μετάδοση/Λήψη)
NR	New Radio (Νέα Ραδιοτεχνολογία του 5G)
URLLC	Ultra-Reliable Low Latency Communication (Επικοινωνία Εξαιρετικά Αξιόπιστη με Χαμηλή Καθυστέρηση)
IoT	Internet of Things (Διαδίκτυο των Πραγμάτων)
AR	Augmented Reality (Επαυξημένη Πραγματικότητα)
VR	Virtual Reality (Εικονική Πραγματικότητα)
V2X	Vehicle-to-Everything (Επικοινωνία Οχήματος με Όλα)
SDN	Software-Defined Networking (Δίκτυα Οριζόμενα από Λογισμικό)
NFV	Network Function Virtualization (Εικονικοποίηση Δικτυακών Λειτουργιών)
QoE	Quality of Experience (Ποιότητα Εμπειρίας)
TD	Temporal Difference (Χρονική Διαφορά)
DP	Dynamic Programming (Δυναμικός Προγραμματισμός)
Massive MIMO	Massive Multiple Input, Multiple Output
MTC	Machine Type Communication

eMBB	Enhanced Mobile Broadband (Ενισχυμένη Κινητή Ευρυζωνικότητα)
------	---

Εικόνες

- 1 https://www.researchgate.net/figure/Types-of-machine-learning-Machine-learning-encompasses-three-main-types-supervised_fig1_373535780
- 2 <https://medium.com/@metehankozan/supervised-and-unsupervised-learning-an-intuitive-approach-cd8f8f64b644>
- 3 <https://datasciencedojo.com/blog/machine-learning-algorithms-explanation>
- 4 <https://datasciencedojo.com/blog/machine-learning-algorithms-explanation/>
- 5 <https://www.linkedin.com/pulse/aipart3regression-vs-classification-models-arnab-mukherjee>
- 6 <https://www.geeksforgeeks.org/underfitting-and-overfitting-in-machine-learning/>
- 7 <https://www.geeksforgeeks.org/underfitting-and-overfitting-in-machine-learning/>
- 8 <https://medium.com/@metehankozan/supervised-and-unsupervised-learning-an-intuitive-approach-cd8f8f64b644>
- 9 <https://datasciencedojo.com/blog/machine-learning-algorithms-explanation/>
- 10 <https://analystprep.com/study-notes/cfa-level-2/quantitative-method/supervised-machine-learning-unsupervised-machine-learning-deep-learning/>
- 11 <https://techvidvan.com/tutorials/reinforcement-learning/>
- 12 Εικόνα που παράχθηκε από την προσομοίωση στο matlab
- 13 Εικόνα που παράχθηκε από την προσομοίωση στο matlab
- 14 Εικόνα που παράχθηκε από την προσομοίωση στο matlab
- 15 Εικόνα που παράχθηκε από την προσομοίωση στο matlab
- 16 Εικόνα που παράχθηκε από την προσομοίωση στο matlab
- 17 Εικόνα που παράχθηκε από την προσομοίωση στο matlab
- 18 Εικόνα που παράχθηκε από την προσομοίωση στο matlab

19 Εικόνα που παράχθηκε από την προσομοίωση στο matlab

20 Εικόνα που παράχθηκε από την προσομοίωση στο matlab

21 Εικόνα που παράχθηκε από την προσομοίωση στο matlab

22 Εικόνα που παράχθηκε από την προσομοίωση στο matlab

Πίνακες

{1} Πίνακας που παράχθηκε μετά την προσομοίωση στο matlab

Μηχανική Μάθηση (Machine learning)

Αρχικά θα μιλήσουμε γενικά για το machine learning και τη λειτουργία των αλγορίθμων του, καθώς και το πως μπορεί να μας βοηθήσει στις επικοινωνίες και θα αναλύσουμε τις υποκατηγορίες του.

Το Machine Learning έχει διεισδύσει σε κάθε πτυχή της σύγχρονης ζωής, από την υγεία και την ιατρική απεικόνιση μέχρι τις μεταφορές και τα αυτόνομα οχήματα. Η ικανότητα των αλγορίθμων μηχανικής μάθησης να αναλύουν τεράστιους όγκους δεδομένων και να εξάγουν χρήσιμες πληροφορίες έχει ανοίξει νέους δρόμους στην ανάπτυξη των δικτύων 5G. Παρόλο που οι δύο αυτοί τομείς φαίνεται να είναι ανεξάρτητοι, η συνύφανσή τους προσφέρει σημαντικά πλεονεκτήματα, όπως θα αναλυθεί στη συνέχεια. Για παράδειγμα, οι αλγόριθμοι ML μπορούν να χρησιμοποιηθούν για τη βελτιστοποίηση της διαχείρισης του φάσματος, την πρόβλεψη της ζήτησης και τη μείωση της καθυστέρησης στα κινητά δίκτυα (5G), συμβάλλοντας έτσι στην παροχή πιο αποτελεσματικών και εξατομικευμένων υπηρεσιών. (Morochó-Cayamcela, Lee, & Lim, 2020), (Morochó-Cayamcela, Lee, M.E., & W.Lim, 2018).

Η μηχανική μάθηση προσφέρει μια ισχυρή εναλλακτική λύση σε προβλήματα που είναι δύσκολο να επιλυθούν με τους παραδοσιακούς αλγόριθμους, όπως οι στατιστικοί ή οι αλγόριθμοι βάσεων δεδομένων. Αυτά τα προβλήματα συχνά χαρακτηρίζονται από υψηλή πολυπλοκότητα, απαιτώντας πολλαπλές ρυθμίσεις και μεταβολές για να βρεθεί μια ικανοποιητική λύση. Η μηχανική μάθηση επιτρέπει στα συστήματα να μαθαίνουν από τα δεδομένα και να ανακαλύπτουν μοτίβα που είναι δύσκολο να εντοπιστούν από τον άνθρωπο, παρακάμπτοντας έτσι την ανάγκη για την δημιουργία εξαιρετικά πολύπλοκων και εύθραυστων κανόνων. (Morochó-Cayamcela, Lee, & Lim, 2020), (Géron, 2017)

Μια machine learning διεργασία μπορεί να αναγνωρίσει ανωμαλίες, να προβλέψει μελλοντικά σενάρια να προσαρμοστεί σε συνεχές μεταβαλλόμενα περιβάλλοντα, να χειριστεί μεγάλου όγκου δεδομένα και να ανακαλύψει συσχετισμούς σε αυτά. Τα ασύρματα δίκτυα και τα δίκτυα κινητής πολλές φορές χρησιμοποιούν προσεγγιστικούς υπολογισμούς μιας και ο ακριβής υπολογισμός προβλημάτων λόγω της μη-γραμμικότητάς τους ή της πολυωνμικότητας είτε είναι αδύνατος είτε ασύμφορος. Σε αυτές τις περιπτώσεις ένας αλγόριθμος machine learning μπορεί να συμβάλει προβλέποντας τις παραμέτρους και εκτιμώντας πράξεις σύμφωνα με τα δεδομένα. Η

μηχανική μάθηση έχει αποδειχθεί ένα ισχυρό εργαλείο για την βελτιστοποίηση των δικτύων 5G. Αλγόριθμοι όπως το Deep Learning επιτρέπουν την ανάλυση μεγάλων όγκων δεδομένων για την πρόβλεψη της ζήτησης, την ανίχνευση ανωμαλιών και την εξατομίκευση των υπηρεσιών. Επιπλέον, το Reinforcement Learning μπορεί να χρησιμοποιηθεί για τη λήψη αποφάσεων σε πραγματικό χρόνο, βελτιστοποιώντας την κατανομή πόρων και την απόδοση του δικτύου. (Li, Chen, Al-Shalash, & Poor, 2015)- (Wang, Han, Chen, & Yang, 2019)

Παρά τις σημαντικές προόδους που έχουν επιτευχθεί, η εφαρμογή της μηχανικής μάθησης στα ασύρματα δίκτυα αντιμετωπίζει ακόμα σημαντικές προκλήσεις. Η ποιότητα και η ποσότητα των διαθέσιμων δεδομένων συχνά αποτελούν περιοριστικό παράγοντα, καθώς τα δεδομένα από τα δίκτυα είναι συχνά θορυβώδη και ανομοιογενή. Επιπλέον, η υψηλή υπολογιστική ισχύς που απαιτείται για την εκπαίδευση και την εκτέλεση πολύπλοκων μοντέλων μηχανικής μάθησης μπορεί να αποτελέσει εμπόδιο, ειδικά σε συσκευές με περιορισμένους πόρους. Επιπλέον, η ερμηνευσιμότητα των μοντέλων αποτελεί ένα σημαντικό ζήτημα, καθώς η αδυναμία να εξηγήσουμε τις αποφάσεις που λαμβάνονται μπορεί να περιορίσει την εμπιστοσύνη των χρηστών. Τέλος, ο χρόνος που απαιτείται για την εκπαίδευση των μοντέλων, ειδικά σε περιβάλλοντα όπου τα δεδομένα αλλάζουν συνεχώς, μπορεί να αποτελέσει πρόκληση (Morochó-Cayamcela, Lee, & Lim, 2020). Για παράδειγμα η εφαρμογή της ενισχυτικής μάθησης σε ετερογενή δίκτυα απαιτεί μεγάλο όγκο δεδομένων εκπαίδευσης και μπορεί να είναι υπολογιστικά απαιτητική. (Li, Chen, Al-Shalash, & Poor, 2015)

Η μηχανική μάθηση έχει αναδειχθεί ως ένα κρίσιμο εργαλείο για την εξέλιξη των δικτύων 5G, προσφέροντας δυνατότητες για την ανάλυση μεγάλων όγκων δεδομένων κινητικότητας, την πρόβλεψη της ζήτησης και τη βελτιστοποίηση της απόδοσης του δικτύου σε πραγματικό χρόνο. Οι αλγόριθμοι μηχανικής μάθησης κατηγοριοποιούνται κυρίως σε εποπτευόμενη (supervised learning), μη εποπτευόμενη (un-supervised learning) και ενισχυτική μάθηση (reinforcement learning). Ενώ η εποπτευόμενη μάθηση, όπως τα νευρωνικά δίκτυα, έχει αποδειχθεί αποτελεσματική στην πρόβλεψη της ποιότητας υπηρεσίας και στην ανίχνευση ανωμαλιών (Liu, Chen, Tong, & Li, 2018), η μη εποπτευόμενη μάθηση, όπως οι αλγόριθμοι clustering, βοηθά στην ανακάλυψη κρυφών δομών στα δεδομένα των χρηστών, επιτρέποντας την παροχή εξατομικευμένων υπηρεσιών. Η ενισχυτική μάθηση, από την άλλη πλευρά, επιτρέπει στους παράγοντες του δικτύου να μάθουν να λαμβάνουν αποφάσεις που μεγιστοποιούν

την απόδοση του συστήματος σε ένα δυναμικό περιβάλλον (Mao, Alizadeh, Menache, & Kandula, 2017). Παρά τις σημαντικές προόδους, η εφαρμογή της μηχανικής μάθησης στα δίκτυα 5G αντιμετωπίζει προκλήσεις όπως η ποιότητα και η διαθεσιμότητα των δεδομένων εκπαίδευσης, η υπολογιστική πολυπλοκότητα των αλγορίθμων και η ερμηνευσιμότητα των μοντέλων. Παρ' όλα αυτά, η δυνατότητα της μηχανικής μάθησης να αναλύσει σύνθετα δεδομένα και να λάβει αποφάσεις σε πραγματικό χρόνο την καθιστά μια κεντρική τεχνολογία για την εξέλιξη των δικτύων 5G και την υποστήριξη νέων εφαρμογών, όπως το Internet των Πραγμάτων και τα αυτόνομα οχήματα. (Samarakoon, Bennis, & Latva-aho, 2019)




Figure 1 Παράδειγμα ομαδοποίησης Μηχανικής Μάθησης

Επιβλεπόμενη Μάθηση (Supervised learning)

Η επιβλεπόμενη μάθηση αποτελεί έναν από τους κεντρικούς πυλώνες της μηχανικής μάθησης, όπου οι αλγόριθμοι εκπαιδεύονται χρησιμοποιώντας ετικετοποιημένα δεδομένα. Στην περίπτωση αυτή, τα δεδομένα εισόδου x συνοδεύονται από τις αντίστοιχες ετικέτες y , οι οποίες παρέχουν τις γνωστές λύσεις για κάθε παρατήρηση (Russell & Norvig, 2010).

Ο στόχος της επιβλεπόμενης μάθησης είναι η ανάπτυξη ενός μοντέλου που μπορεί να γενικεύσει και να κάνει προβλέψεις για νέα, μη ετικετοποιημένα δεδομένα.

Για να διατυπώσουμε το πρόβλημα της επιβλεπόμενης μάθησης, υποθέτουμε ότι έχουμε ένα σύνολο δεδομένων $S = \{(x_i, y_i)\}_{i=1}^n$, όπου n είναι ο αριθμός των παρατηρήσεων. Ο αλγόριθμος μας, ο οποίος θα ονομάσουμε f , επιδιώκει να βρει μια

συνάρτηση $f: X \rightarrow Y$, έτσι ώστε να ελαχιστοποιεί την απώλεια μεταξύ των προβλέψεων και των πραγματικών ετικετών. Η ποιότητα της πρόβλεψης αξιολογείται μέσω μιας συνάρτησης απώλειας $L(y, f(x))$, η οποία μετρά τη διαφορά μεταξύ των προβλέψεων $f(x)$ και των πραγματικών τιμών y .

Η επιλογή της συνάρτησης απώλειας εξαρτάται από τη φύση του προβλήματος. Σε περιπτώσεις ταξινόμησης, μπορεί να χρησιμοποιηθεί η συνάρτηση απώλειας $\log$ loss (cross-entropy loss):

$$L(y, f(x)) = -\sum_{k=1}^K y_k \log(f_k(x))$$

όπου K είναι ο αριθμός των κατηγοριών και $f_k(x)$ είναι η πιθανότητα που δίνει το μοντέλο για την κατηγορία k . (Goodfellow, Bengio, & Courville, 2016) Σε περιπτώσεις παλινδρόμησης, η μέση τετραγωνική απόκλιση (Mean Squared Error) συχνά χρησιμοποιείται:

$$L(y, f(x)) = (1/n) \sum_{i=1}^n (y_i - f(x_i))^2$$

Ο στόχος του αλγορίθμου είναι να βρει τις παραμέτρους θ που ελαχιστοποιούν τη συνάρτηση απώλειας. Αυτό διατυπώνεται ως:

$$\theta' = \operatorname{argmin}_{\theta} L(y, f(x; \theta))$$

Η ελαχιστοποίηση μπορεί να επιτευχθεί μέσω διαφόρων μεθόδων βελτιστοποίησης, όπως η μέθοδος gradient descent, η οποία ενημερώνει τις παραμέτρους με τον εξής τύπο:

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} L(y, f(x; \theta_t))$$

όπου η είναι το learning rate και $\nabla_{\theta} L$ είναι το διάνυσμα των παραγώγων της συνάρτησης απώλειας σε σχέση με τις παραμέτρους θ (Bishop, 2006).

Supervised Learning




Figure 2 Επιβλεπόμενη Μάθηση

Στην επιβλεπόμενη μάθηση, τα προβλήματα που καλείται να επιλύσει ένας αλγόριθμος συνήθως χωρίζονται σε δύο κύριες κατηγορίες: **παλινδρόμηση (regression)** και **ταξινόμηση (classification)**. Και οι δύο κατηγορίες έχουν διαφορετικούς στόχους και αντιμετωπίζονται με διαφορετικά μαθηματικά μοντέλα, τα οποία προσπαθούν να βελτιστοποιήσουν συναρτήσεις απώλειας.

Ταξινόμηση (Classification)

Στην **ταξινόμηση**, ο στόχος είναι η πρόβλεψη κατηγοριών, δηλαδή διακριτών τιμών εξόδου. Δίνεται ένα σύνολο δεδομένων (x_i, y_i) , όπου x_i είναι τα δεδομένα εισόδου και $y_i \in \{1, 2, \dots, K\}$ είναι οι κατηγορίες. Σε αυτή την περίπτωση, η συνάρτηση $f(x)$ προβλέπει σε ποια κατηγορία ανήκει το x . (Goodfellow, Bengio, & Courville, 2016)

Ένας δημοφιλής αλγόριθμος ταξινόμησης είναι η **λογιστική παλινδρόμηση (logistic regression)**, η οποία χρησιμοποιείται για δυαδικά προβλήματα ταξινόμησης, όπου οι κατηγορίες είναι $y \in \{0, 1\}$. Η λογιστική παλινδρόμηση προβλέπει την πιθανότητα η παρατήρηση να ανήκει στην κατηγορία 1, με τη συνάρτηση:

$$P(y = 1 | x) = \frac{1}{1 + e^{-\beta^T x}}$$




Figure 3 Λογιστική Παλινδρόμηση

Η συνάρτηση απώλειας για την λογιστική παλινδρόμηση είναι η **διασταυρούμενη εντροπία (cross-entropy loss)**:

$$L(\beta) = -\frac{1}{n} \sum_{i=1}^n [y_i \log P(y_i) + (1 - y_i) \log(1 - P(y_i))]$$

Η ελαχιστοποίηση της συνάρτησης απώλειας πραγματοποιείται συνήθως μέσω της **μεθόδου καθόδου της κλίσης (gradient descent)**, όπου οι παράμετροι β ενημερώνονται ως εξής:

$$\beta_{t+1} = \beta_t - \eta \nabla_{\beta} L(\beta)$$

όπου η είναι ο ρυθμός μάθησης (learning rate) και $\nabla_{\beta} L(\beta)$ είναι η παράγωγος της συνάρτησης απώλειας ως προς τις παραμέτρους β .

Παλινδρόμηση (Regression):

Η παλινδρόμηση έχει ως στόχο την πρόβλεψη συνεχών τιμών εξόδου. Δίνεται ένα σύνολο δεδομένων (x_i, y_i) , όπου x_i είναι τα δεδομένα εισόδου και $y_i \in \mathbb{R}$ οι αντίστοιχες

συνεχείς τιμές εξόδου. Ο στόχος είναι η εύρεση μιας συνάρτησης $f(x)$, που προσεγγίζει τη σχέση μεταξύ x και y . (Bishop, 2006)

Η πιο συνηθισμένη μορφή παλινδρόμησης είναι η γραμμική παλινδρόμηση, όπου η συνάρτηση $f(x)$ έχει τη μορφή: $f(x)=\beta_0+\beta_1x_1+\beta_2x_2+\dots+\beta_px_p=X\beta$. Για την εκτίμηση των παραμέτρων β , χρησιμοποιούμε τη μέθοδο των ελαχίστων τετραγώνων (Ordinary Least Squares, OLS), η οποία ελαχιστοποιεί τη συνάρτηση κόστους:

$$J(\beta)=\frac{1}{2n}\sum_{i=1}^n(y_i - X_i\beta)^2$$

Η λύση για τη βελτιστοποίηση της παραπάνω συνάρτησης δίνεται από: $\beta=(X^TX)^{-1}X^Ty$ όπου X^T είναι ο ανάστροφος πίνακας και y είναι το διάνυσμα των παρατηρήσεων εξόδου.




Figure 4 Γραμμική Παλινδρόμηση

Διαφορές μεταξύ Παλινδρόμησης και Ταξινόμησης

- Στην παλινδρόμηση, η τιμή εξόδου είναι συνεχής, ενώ στην ταξινόμηση είναι διακριτή. (Hastie, Tibshirani, & Friedman, 2009)

- Η συνάρτηση απώλειας για την παλινδρόμηση είναι η μέση τετραγωνική απόκλιση (MSE), ενώ στην ταξινόμηση χρησιμοποιείται η διασταυρούμενη εντροπία. (Bishop, 2006), (Goodfellow, Bengio, & Courville, 2016)
- Η γραμμική παλινδρόμηση είναι μέθοδος άμεσης πρόβλεψης, ενώ η λογιστική παλινδρόμηση εκτιμά πιθανότητες. (Hastie, Tibshirani, & Friedman, 2009)




Figure 5 Ταξινόμηση vs Παλινδρόμηση

Ένας πρωταρχικός στόχος της επιβλεπόμενης μάθησης είναι η εξασφάλιση της γενίκευσης, δηλαδή της ικανότητας ενός μοντέλου να εκτελεί ακριβείς προβλέψεις σε μη ορατά κατά την εκπαίδευση δεδομένα. Η αποτυχία επίτευξης επαρκούς γενίκευσης αποδίδεται συχνά σε φαινόμενα υπερπροσαρμογής (overfitting) και υποπροσαρμογής (underfitting). Ειδικότερα, η υπερπροσαρμογή αναφέρεται στην τάση ενός μοντέλου να "απομνημονεύει" τα εκπαιδευτικά δεδομένα με υπερβολική ακρίβεια, οδηγώντας σε κακή απόδοση σε νέα δεδομένα λόγω της υψηλής διακύμανσης του μοντέλου. Αντιθέτως, η υποπροσαρμογή εμφανίζεται όταν ένα μοντέλο δεν είναι αρκετά πολύπλοκο για να συλλάβει τις υποκείμενες σχέσεις στα δεδομένα, περιορίζοντας τη δυνατότητά του να πραγματοποιήσει ακριβείς προβλέψεις. Η αντιμετώπιση αυτών των φαινομένων αποτελεί κεντρικό ερευνητικό ζήτημα στον τομέα της μηχανικής μάθησης, με προτάσεις όπως η κανονικοποίηση (regularization), η χρήση διασταυρούμενης επικύρωσης (cross-validation), η έγκαιρη διακοπή της εκπαίδευσης, η επιλογή μοντέλων και η διαχείριση των υπερπαραμέτρων να αποτελούν κοινές τεχνικές για την βελτίωση της γενίκευσης. (Bishop, 2006), (Hastie, Tibshirani, & Friedman, 2009)

Στη Μηχανική Μάθηση (Machine Learning), οι έννοιες της μεροληψίας (bias) και της διακύμανσης (variance) είναι κρίσιμες για την αξιολόγηση της απόδοσης των μοντέλων και τη διαχείριση του φαινομένου της υπερπροσαρμογής (overfitting) ή της υποπροσαρμογής (underfitting). Αυτές οι δύο παράμετροι αντικατοπτρίζουν τα είδη των σφαλμάτων που μπορεί να αντιμετωπίσει ένα μοντέλο και συνδέονται άμεσα με την ικανότητά του να γενικεύει καλά σε νέα, αθέατα δεδομένα. (Goodfellow, Bengio, & Courville, 2016)

Μεροληψία (Bias)

Η μεροληψία είναι η τάση ενός μοντέλου να κάνει συστηματικά σφάλματα λόγω των υποθέσεων που χρησιμοποιεί για να μοντελοποιήσει τα δεδομένα. Μια υψηλή μεροληψία σημαίνει ότι το μοντέλο δε μπορεί να καταγράψει καλά την πολυπλοκότητα των δεδομένων, συνήθως επειδή είναι υπερβολικά απλό για το πρόβλημα. Αυτή η κατάσταση οδηγεί σε υποπροσαρμογή (underfitting), δηλαδή το μοντέλο δεν αποδίδει καλά ούτε στα δεδομένα εκπαίδευσης ούτε στα δεδομένα δοκιμής. (Bishop, 2006)

Παραδείγματα υψηλής μεροληψίας εμφανίζονται συνήθως όταν χρησιμοποιούμε πολύ απλά μοντέλα, όπως η γραμμική παλινδρόμηση (linear regression) για ένα πρόβλημα που απαιτεί πιο περίπλοκη μοντελοποίηση. Σε αυτήν την περίπτωση, η υψηλή μεροληψία εμποδίζει το μοντέλο να μάθει τις σύνθετες σχέσεις στα δεδομένα, με αποτέλεσμα τη δημιουργία σφαλμάτων τόσο στα δεδομένα εκπαίδευσης όσο και στα δεδομένα δοκιμής. (Friedman, Hastie, & Tibshirani, 2001)

Διακύμανση (Variance)

Η διακύμανση αναφέρεται στην ευαισθησία του μοντέλου σε αλλαγές στα δεδομένα εκπαίδευσης. Ένα μοντέλο με υψηλή διακύμανση μπορεί να αποδίδει πολύ καλά στα δεδομένα εκπαίδευσης, αλλά δεν καταφέρνει να γενικεύσει σε νέα δεδομένα, παρουσιάζοντας υπερπροσαρμογή (overfitting). Αυτό συμβαίνει επειδή το μοντέλο έχει μάθει να απομνημονεύει τα δεδομένα εκπαίδευσης αντί να εξαγάγει γενικές σχέσεις, κάτι που οδηγεί σε μεγάλο σφάλμα στα δεδομένα δοκιμής. (Geman, Bienenstock, & Doursat, 1992)

Η υψηλή διακύμανση εμφανίζεται συνήθως σε πολύπλοκα μοντέλα, όπως τα νευρωνικά δίκτυα ή τα δέντρα απόφασης (decision trees) με μεγάλο βάθος. Αυτά τα μοντέλα μπορούν να προσαρμόσουν πολύ καλά τα δεδομένα εκπαίδευσης, αλλά αποτυγχάνουν να αναγνωρίσουν τις γενικές τάσεις και επομένως δεν αποδίδουν καλά σε νέα δείγματα.

Το Δίλημμα Μεροληψίας-Διακύμανσης (Bias-Variance Trade-off)

Το ιδανικό μοντέλο έχει ισορροπία μεταξύ της μεροληψίας και της διακύμανσης, ώστε να αποδίδει καλά σε δεδομένα εκπαίδευσης και δοκιμής. Αυτό είναι γνωστό ως δίλημμα μεροληψίας-διακύμανσης (bias-variance trade-off). Συνήθως, καθώς μειώνουμε τη μεροληψία αυξάνεται η διακύμανση και αντίστροφα. (Goodfellow, Bengio, & Courville, 2016)

- **Χαμηλή Μεροληψία και Χαμηλή Διακύμανση:** Ιδανική κατάσταση αλλά δύσκολα επιτεύξιμη στην πράξη.
- **Χαμηλή Μεροληψία και Υψηλή Διακύμανση:** Το μοντέλο αποδίδει καλά στην εκπαίδευση αλλά έχει υπερπροσαρμοστεί, με αποτέλεσμα κακή απόδοση σε νέα δεδομένα.
- **Υψηλή Μεροληψία και Χαμηλή Διακύμανση:** Το μοντέλο δεν μπορεί να μάθει σωστά τις σχέσεις στα δεδομένα, παρουσιάζοντας υποπροσαρμογή.
- **Υψηλή Μεροληψία και Υψηλή Διακύμανση:** Το χειρότερο σενάριο, όπου το μοντέλο αποτυγχάνει να αποδώσει τόσο στα δεδομένα εκπαίδευσης όσο και στα δεδομένα δοκιμής.

Μαθηματική Διατύπωση

Το συνολικό σφάλμα του μοντέλου μπορεί να διατυπωθεί ως εξής:

$$Total Error = Bias^2 + Variance + Irreducible Error$$

- **Μεροληψία (Bias):** Το τετράγωνο της απόκλισης της προβλεπόμενης τιμής από την πραγματική, δηλαδή η συστηματική απόκλιση από το στόχο.
- **Διακύμανση (Variance):** Η ευαισθησία της απόδοσης του μοντέλου στις αλλαγές των δεδομένων εκπαίδευσης.

- **Μη Μειώσιμο Σφάλμα (Irreducible Error):** Ένα σφάλμα που δεν μπορούμε να μειώσουμε λόγω θορύβου ή αβεβαιότητας στα δεδομένα.

Το *δίλημμα μεροληψίας-διακύμανσης* επιδιώκει να βρει τη βέλτιστη ισορροπία μεταξύ αυτών των δύο μεγεθών ώστε να μεγιστοποιηθεί η γενικευτική ικανότητα του μοντέλου, επιτυγχάνοντας έτσι καλή απόδοση τόσο στα δεδομένα εκπαίδευσης όσο και στα δεδομένα δοκιμής.




Figure 6 bias vs variance

Υπερπροσαρμογή (Overfitting)

Η υπερπροσαρμογή (overfitting) είναι ένα κρίσιμο ζήτημα στη μηχανική μάθηση, που εμφανίζεται όταν ένα μοντέλο προσαρμόζεται υπερβολικά στα δεδομένα εκπαίδευσης, απορροφώντας τόσο τα χρήσιμα μοτίβα όσο και τον θόρυβο. Αυτό οδηγεί σε εξαιρετική απόδοση στα δεδομένα εκπαίδευσης, αλλά σημαντική μείωση της ικανότητας γενίκευσης σε νέα, αθέατα δεδομένα. (Goodfellow, Bengio, & Courville, 2016)

Χαρακτηριστικά της Υπερπροσαρμογής

- **Υψηλή Ακρίβεια Εκπαίδευσης:** Τα υπερπροσαρμοσμένα μοντέλα εμφανίζουν εξαιρετικά υψηλή απόδοση στα δεδομένα εκπαίδευσης, καταφέρνοντας να συλλάβουν ακόμη και τον θόρυβο στα δεδομένα, κάτι που οδηγεί σε φαινομενικά χαμηλό σφάλμα εκπαίδευσης.

- **Χαμηλή Ακρίβεια Δοκιμής:** Αντίθετα, η ακρίβεια στα δεδομένα δοκιμής είναι χαμηλή, καθώς το μοντέλο αδυνατεί να γενικεύσει καλά, με αποτέλεσμα να αποδίδει άσχημα όταν εκτίθεται σε νέα δεδομένα . (Hastie, Tibshirani, & Friedman, 2009)
- **Πολύπλοκο Μοντέλο:** Η υπερπροσαρμογή συνδέεται συχνά με πολύπλοκα μοντέλα, τα οποία έχουν περισσότερες παραμέτρους από ό,τι χρειάζεται για να προσαρμοστεί στα δεδομένα εκπαίδευσης. Αυτά τα μοντέλα μαθαίνουν λεπτομέρειες και ιδιαιτερότητες που δεν είναι αντιπροσωπευτικές της γενικότερης τάσης των δεδομένων. (Zhang, Bengio, Hardt, Recht, & Vinyals, 2021)

Μαθηματική Περιγραφή της Υπερπροσαρμογής

Η υπερπροσαρμογή προκύπτει όταν το μοντέλο ελαχιστοποιεί το σφάλμα εκπαίδευσης αλλά μεγιστοποιεί το σφάλμα δοκιμής. Ένα παράδειγμα υπερπροσαρμοσμένου μοντέλου μπορεί να περιγραφεί από μια υπόθεση με υπερβολικά μεγάλο βαθμό πολυωνύμου, π.χ.:

$$h(x) = \theta_0 + \theta_1 x + \theta_2 x^2 + \dots + \theta_n x^n$$

Σε αυτήν την περίπτωση, το μοντέλο προσαρμόζεται πολύ καλά στα δεδομένα εκπαίδευσης, ακολουθώντας τον θόρυβο, αλλά αποτυγχάνει να γενικεύσει όταν έρχεται αντιμέτωπο με νέα δεδομένα. Η αύξηση της πολυπλοκότητας οδηγεί σε αύξηση της διακύμανσης (variance) του σφάλματος, με τη σχέση μεταξύ διακύμανσης και απόκλισης (bias) να δίνεται από τον τύπο:

$$\text{Σφάλμα} = \text{Bias}^2 + \text{Variance} + \text{Irreducible Error}$$

Στην υπερπροσαρμογή, η διακύμανση αυξάνεται υπερβολικά, ενώ το Bias^2 παραμένει χαμηλό, οδηγώντας σε γενικά υψηλό σφάλμα.

Αντιμετώπιση της Υπερπροσαρμογής

1. **Κανονικοποίηση (Regularization):** Η προσθήκη τεχνικών κανονικοποίησης, όπως η L1 (lasso) και η L2 (ridge) κανονικοποίηση, βοηθά στην αποφυγή της υπερπροσαρμογής περιορίζοντας τις τιμές των παραμέτρων του μοντέλου. Η L2 κανονικοποίηση, για παράδειγμα, προσθέτει έναν όρο ποινής στην απώλεια (loss function), μειώνοντας τη διακύμανση του μοντέλου και αυξάνοντας την ικανότητα γενίκευσης (Ng, 2004):

$$L(w) = \sum (y_i - h(x_i))^2 + \lambda \sum w^j{}^2$$

2. **Διασταυρούμενη Επικύρωση (Cross-Validation):** Η χρήση μεθόδων όπως η διασταυρούμενη επικύρωση k-fold, όπου το σύνολο δεδομένων διαιρείται σε k υποσύνολα και το μοντέλο εκπαιδεύεται σε διαφορετικά υποσύνολα, βοηθά στην αποφυγή της υπερπροσαρμογής και βελτιώνει τη γενίκευση του μοντέλου (Hastie, Tibshirani, & Friedman, 2009).
3. **Early Stopping:** Στην περίπτωση των νευρωνικών δικτύων, η τεχνική του early stopping, όπου η εκπαίδευση διακόπτεται μόλις η απόδοση σε ένα σύνολο επικύρωσης αρχίσει να μειώνεται, αποτελεί αποτελεσματικό μέτρο για την αποφυγή της υπερπροσαρμογής. (Goodfellow, Bengio, & Courville, 2016)
4. **Μείωση της Πολυπλοκότητας του Μοντέλου:** Η μείωση των παραμέτρων του μοντέλου ή η επιλογή απλούστερων μοντέλων μπορεί να βοηθήσει στην αποφυγή της υπερπροσαρμογής. Μοντέλα με λιγότερες παραμέτρους είναι λιγότερο επιρρεπή στο να προσαρμόζονται στον θόρυβο των δεδομένων. (Zhang, Bengio, Hardt, Recht, & Vinyals, 2021)
5. **Προσθήκη Περισσότερων Δεδομένων:** Η αύξηση του αριθμού των παρατηρήσεων μπορεί να μειώσει την υπερπροσαρμογή, καθώς το μοντέλο έχει στη διάθεσή του περισσότερα δεδομένα για να μάθει και να γενικεύσει καλύτερα. (Hastie, Tibshirani, & Friedman, 2009)

Υποπροσαρμογή (Underfitting)

Η υποπροσαρμογή (underfitting) συμβαίνει όταν ένα μοντέλο είναι υπερβολικά απλό για να συλλάβει τα μοτίβα των δεδομένων. Αυτό έχει ως αποτέλεσμα χαμηλή ακρίβεια τόσο στα δεδομένα εκπαίδευσης όσο και στα δεδομένα δοκιμής. (Goodfellow, Bengio, & Courville, 2016)

Χαρακτηριστικά της Υποπροσαρμογής

- **Χαμηλή Ακρίβεια Εκπαίδευσης:** Τα υποπροσαρμοσμένα μοντέλα αποτυγχάνουν να αποδώσουν καλά στα δεδομένα εκπαίδευσης, καθώς δεν καταφέρνουν να συλλάβουν τις κύριες τάσεις των δεδομένων.
- **Χαμηλή Ακρίβεια Δοκιμής:** Τα υποπροσαρμοσμένα μοντέλα αποτυγχάνουν να αποδώσουν καλά και στα δεδομένα δοκιμής, καθώς δεν έχουν μάθει επαρκώς τα μοτίβα. (Hastie, Tibshirani, & Friedman, 2009)

- **Απλό Μοντέλο:** Η υποπροσαρμογή προκύπτει συχνά σε μοντέλα που είναι υπερβολικά απλά, με λίγες παραμέτρους, σε σχέση με την πολυπλοκότητα των δεδομένων. (Zhang, Bengio, Hardt, Recht, & Vinyals, 2021)

Μαθηματική Περιγραφή της Υποπροσαρμογής

Στα υποπροσαρμοσμένα μοντέλα, το τετράγωνο της απόκλισης (bias) είναι υψηλό, ενώ η διακύμανση είναι χαμηλή. Το σφάλμα του μοντέλου μπορεί να εκφραστεί ως:

$$\text{Σφάλμα} = \text{Bias}^2 + \text{Variance} + \text{Irreducible Error}$$

Στην περίπτωση της υποπροσαρμογής, το Bias^2 κυριαρχεί, καθώς το μοντέλο δεν μπορεί να προσαρμοστεί επαρκώς στις σχέσεις των δεδομένων.

Αντιμετώπιση της Υποπροσαρμογής

1. **Αύξηση της Πολυπλοκότητας του Μοντέλου:** Η υποπροσαρμογή μπορεί να αντιμετωπιστεί με την επιλογή πιο σύνθετων μοντέλων, όπως η χρήση μη γραμμικών μοντέλων ή περισσότερων παραμέτρων. (Hastie, Tibshirani, & Friedman, 2009)
2. **Κανονικοποίηση:** Όπως και με την υπερπροσαρμογή, οι τεχνικές κανονικοποίησης μπορούν να βοηθήσουν στην αποφυγή της υποπροσαρμογής, εξασφαλίζοντας ότι το μοντέλο δεν είναι πολύ απλό. (Ng, 2004)
3. **Επιλογή Χαρακτηριστικών:** Η επιλογή πιο σχετικών χαρακτηριστικών μπορεί να βελτιώσει την ικανότητα του μοντέλου να συλλαμβάνει τα υποκείμενα μοτίβα στα δεδομένα. (Zhang, Bengio, Hardt, Recht, & Vinyals, 2021)
4. **Αύξηση του Όγκου των Δεδομένων:** Η συλλογή περισσότερων δεδομένων εκπαίδευσης μπορεί να βοηθήσει το μοντέλο να μάθει καλύτερα τα υποκείμενα μοτίβα, μειώνοντας την υποπροσαρμογή. (Goodfellow, Bengio, & Courville, 2016)




Figure 7 under-fitting vs over-fitting

Μετατόπιση του Συνόλου Δεδομένων: Μια Κρίσιμη Πρόκληση στη Μηχανική Μάθηση

Η μετατόπιση του συνόλου δεδομένων, ένα φαινόμενο όπου οι στατιστικές ιδιότητες των δεδομένων εκπαίδευσης διαφέρουν από εκείνες των δεδομένων δοκιμής, αποτελεί μια σημαντική πρόκληση στη μηχανική μάθηση (Ben-David, Blitzer, Crammer, & Pereira, 2007). Αυτή η διαφορά μπορεί να υπονομεύσει σοβαρά την απόδοση και τη γενίκευση των μοντέλων μας, οδηγώντας σε ανακριβείς προβλέψεις σε πραγματικές εφαρμογές.

Τύποι Μετατόπισης

Η μετατόπιση του συνόλου δεδομένων μπορεί να εκδηλωθεί με διάφορους τρόπους, όπως:

- **Μετατόπιση συμμεταβλητής:** Αλλαγή στη κατανομή των εισόδων (συμμεταβλητών) χωρίς αλλαγή στη σχέση μεταξύ εισόδων και εξόδων. Για παράδειγμα, σε συστήματα ανίχνευσης ανεπιθύμητων μηνυμάτων, η συχνότητα εμφάνισης ορισμένων λέξεων μπορεί να μεταβληθεί με την πάροδο του χρόνου. (Quinonero-Candela, Sugiyama, Schwaighofer, & Lawrence, 2009)
- **Μετατόπιση προγενέστερης πιθανότητας:** Αλλαγή στις προγενέστερες πιθανότητες των διαφορετικών κατηγοριών. Για παράδειγμα, σε ένα σύστημα ιατρικής διάγνωσης, η επικράτηση μιας συγκεκριμένης ασθένειας μπορεί να μεταβληθεί λόγω νέων θεραπειών ή επιδημιών.

- **Παρασυρόμενη έννοια:** Αλλαγή στη σχέση μεταξύ εισόδων και εξόδων. Για παράδειγμα, σε συστήματα ανίχνευσης απάτης, οι μέθοδοι που χρησιμοποιούν οι απατεώνες μπορεί να εξελιχθούν με την πάροδο του χρόνου.
- **Μετατόπιση τομέα:** Διαφορά στον τομέα των δεδομένων εκπαίδευσης και δοκιμής. Για παράδειγμα, ένα μοντέλο εκπαιδευμένο σε εικόνες υψηλής ανάλυσης μπορεί να αποτύχει σε εικόνες χαμηλής ανάλυσης.
- **Μετατόπιση στόχου:** Αλλαγή στην κατανομή των εξόδων. Για παράδειγμα, σε συστήματα συστάσεων, η δημοτικότητα των προϊόντων μπορεί να μεταβληθεί με την πάροδο του χρόνου.

Ανίχνευση και Αντιμετώπιση

Για να ανιχνεύσουμε τη μετατόπιση του συνόλου δεδομένων, μπορούμε να χρησιμοποιήσουμε τεχνικές όπως την οπτική επιθεώρηση διαγραμμάτων κατανομής ή στατιστικά τεστ όπως το Kolmogorov-Smirnov. Για να την αντιμετωπίσουμε, μπορούμε να εφαρμόσουμε διάφορες στρατηγικές, ανάλογα με τον τύπο της μετατόπισης. Για παράδειγμα, για τη μετατόπιση συμμεταβλητής, η χρήση βαρών σημαντικότητας (Shimodaira, 2000) μπορεί να βοηθήσει.

Επιπτώσεις και Εφαρμογές

Οι επιπτώσεις της μετατόπισης του συνόλου δεδομένων μπορεί να είναι σημαντικές, ειδικά σε τομείς όπως η ιατρική διάγνωση, όπου λανθασμένες προβλέψεις μπορεί να έχουν σοβαρές συνέπειες. Για παράδειγμα, η μετατόπιση προγενέστερης πιθανότητας λόγω νέων επιδημιών μπορεί να οδηγήσει σε λανθασμένες διαγνώσεις αν δεν αντιμετωπιστεί κατάλληλα.

Η κατανόηση και η αντιμετώπιση της μετατόπισης του συνόλου δεδομένων είναι κρίσιμη για την ανάπτυξη αξιόπιστων μοντέλων μηχανικής μάθησης. Με την εφαρμογή κατάλληλων τεχνικών και την συνεχή παρακολούθηση των δεδομένων, μπορούμε να μειώσουμε τις επιπτώσεις της μετατόπισης και να βελτιώσουμε την απόδοση των μοντέλων μας σε πραγματικές εφαρμογές.

Μη Εποπτευόμενη Μάθηση (Un-supervised learning)

Εισαγωγή

Η μη εποπτευόμενη μάθηση αποτελεί έναν από τους βασικούς πυλώνες της μηχανικής μάθησης, προσφέροντας δυνατότητες για εξαγωγή γνώσης και κατανόηση μοτίβων από δεδομένα χωρίς τη χρήση προκαθορισμένων ετικετών ή άλλων σχολιασμών. Η απουσία «βάσης αλήθειας» διαφοροποιεί τη μη εποπτευόμενη μάθηση από την εποπτευόμενη, επιτρέποντας την ανίχνευση συσχετίσεων και δομών που δεν είναι εκ των προτέρων γνωστές. Σύμφωνα με τον (Goodfellow, Bengio, & Courville, 2016) “η μη εποπτευόμενη μάθηση είναι κεντρικής σημασίας για πεδία όπως η αναγνώριση προτύπων, η ομαδοποίηση, και η ανάλυση μεγάλων βάσεων δεδομένων, όπου οι ετικέτες είναι δύσκολο να εξασφαλιστούν ή δεν είναι διαθέσιμες.”




Figure 8 Μη Εποπτευόμενη Μάθηση

Θεμελιώδεις Έννοιες

1. **Δεδομένα χωρίς Ετικέτες:** Τα δεδομένα που χρησιμοποιούνται στη μη εποπτευόμενη μάθηση δεν περιλαμβάνουν προκαθορισμένες ετικέτες. Η μη εποπτευόμενη μάθηση επιχειρεί να ανιχνεύσει τις εγγενείς δομές που κρύβονται μέσα στα δεδομένα, χωρίς να χρειάζεται εξωτερική καθοδήγηση.
2. **Στόχος:** Η κατανόηση των δομών στα δεδομένα γίνεται μέσω της εξαγωγής κρυμμένων σχέσεων, οι οποίες μπορούν να χρησιμοποιηθούν για καλύτερη οπτικοποίηση και αναπαράσταση. Ο στόχος είναι η εκμάθηση των κρυφών

χαρακτηριστικών που κατευθύνουν τα δεδομένα, αναγνωρίζοντας μοτίβα που ενδεχομένως παραμένουν αδιόρατα σε άλλες μεθόδους.

Τύποι Μη Εποπτευόμενης Μάθησης

1. Ομαδοποίηση (Clustering)

Στην ομαδοποίηση, τα αντικείμενα οργανώνονται σε ομάδες, όπου κάθε ομάδα περιλαμβάνει αντικείμενα που είναι πιο παρόμοια μεταξύ τους από ό,τι με αντικείμενα άλλων ομάδων (Jain, Murty, & Flynn, 1999). Μερικοί από τους σημαντικότερους αλγόριθμους είναι οι εξής:

- **K-means:** Ο αλγόριθμος αυτός προσπαθεί να ελαχιστοποιήσει την ενδο-ομαδική διασπορά (within-cluster variance). Το μαθηματικό μοντέλο του βασίζεται στη μείωση της απόστασης από τα σημεία δεδομένων προς το πλησιέστερο κέντρο ομάδας (c_i) ως εξής:

$$J = \sum_{i=1}^k \sum_{xj \in C_i} \|xj - c_i\|^2$$

όπου C_i είναι η ομάδα και xj είναι το σημείο δεδομένων (MacQueen, 1967). Ωστόσο, ο αλγόριθμος είναι ευαίσθητος στην αρχική επιλογή των κέντρων.




Figure 9 K-means

- **Ιεραρχική Ομαδοποίηση:** Δημιουργεί ιεραρχικές σχέσεις μεταξύ των ομάδων. Στην συγκεντρωτική ομαδοποίηση (agglomerative), ξεκινά με κάθε δεδομένο ως μια ξεχωριστή ομάδα και συγχωνεύει τις πιο κοντινές ομάδες επαναληπτικά. (Murtagh & Contreras, 2012)

- **DBSCAN (Density-Based Spatial Clustering of Applications with Noise):** Ομαδοποιεί περιοχές υψηλής πυκνότητας ενώ απομονώνει τις αραιές περιοχές ως εξωγενείς (Ester, Kriegel, Sander, & Xu, 1996).




Figure 10 Ομαδοποίηση (Clustering)

2. Μείωση Διαστάσεων (Dimensionality Reduction)

Η μείωση διαστάσεων χρησιμοποιείται για τη συμπίεση των δεδομένων σε χώρους χαμηλότερων διαστάσεων, διατηρώντας την ουσία της πληροφορίας. Παραδείγματα αλγορίθμων μείωσης διαστάσεων περιλαμβάνουν:

- **Ανάλυση Κύριων Συνιστωσών (Principal Component Analysis, PCA):** Ο στόχος είναι η μέγιστη απόδοση της διασποράς στα δεδομένα, προβάλλοντάς τα σε ένα χώρο χαμηλότερων διαστάσεων. Ορίζεται ως:

$$\max_{W} \text{Tr}(W^T S W)$$

όπου W είναι το μήκος των συνιστωσών και S ο πίνακας συνδιακύμανσης (Jolliffe & Cadima, 2016).

- **t-SNE (t-Distributed Stochastic Neighbor Embedding):** Χρησιμοποιείται για την οπτικοποίηση δεδομένων υψηλής διάστασης. (van der Maaten & Hinton, 2008)

3. Ανίχνευση Ανωμαλιών (Anomaly Detection)

Η ανίχνευση ανωμαλιών στοχεύει στον εντοπισμό σπάνιων ή ακραίων σημείων δεδομένων που αποκλίνουν από το υπόλοιπο σύνολο. Δημοφιλείς αλγόριθμοι περιλαμβάνουν:

- **Isolation Forest:** Χρησιμοποιεί δέντρα απόφασης για την απομόνωση των ανωμαλιών, καθώς αυτές απαιτούν λιγότερες διασπάσεις για να απομονωθούν. (Liu, Ting, & Zhou, 2008)
- **Μηχανή Υποστήριξης Μιας Κλάσης (One-Class SVM):** Καθορίζει μια απόφαση διαχωρισμού που περικλείει τα κανονικά δεδομένα σε έναν χώρο υψηλών διαστάσεων. (Schölkopf, Smola, Williamson, & Ba, 2001)

4. Μάθηση Κανόνων Συσχέτισης (Association Rule Learning)

Ανακαλύπτει ενδιαφέρουσες σχέσεις μεταξύ μεταβλητών σε μεγάλα σύνολα δεδομένων, όπως στην ανάλυση καλαθιού αγορών (Market Basket Analysis) (Agrawal & Srikant, 1994). Δημοφιλείς αλγόριθμοι περιλαμβάνουν:

- **Apriori:** Προσδιορίζει συχνά μοτίβα και δημιουργεί κανόνες συσχέτισης μέσω επαναληπτικής εξαγωγής συχνών συνδυαστικών συνόλων.

Προκλήσεις της Μη Εποπτευόμενης Μάθησης

Η μη εποπτευόμενη μάθηση έχει αναδειχθεί ως ένας ισχυρός τομέας της μηχανικής μάθησης, αλλά περιλαμβάνει πολλές προκλήσεις που περιορίζουν την αποτελεσματικότητα και την εφαρμογή της. Οι κύριες προκλήσεις περιλαμβάνουν:

1. Έλλειψη Βάσης Αλήθειας

Ζήτημα:

Η έλλειψη ετικεταρισμένων δεδομένων καθιστά δύσκολη την επικύρωση των αποτελεσμάτων και της απόδοσης των μη εποπτευόμενων αλγορίθμων.

Επίπτωση:

Η μέτρηση της ακρίβειας και της αποτελεσματικότητας γίνεται συχνά μέσω έμμεσων μεθόδων ή απαιτεί εξειδικευμένη γνώση, η οποία μπορεί να είναι υποκειμενική. (Dua & Graff, 2019)

Μαθηματικό

Μοντέλο:

Η ανάλυση των αποτελεσμάτων μπορεί να περιγραφεί με τη χρήση του δείκτη Rand (Rand, 1971), ο οποίος υπολογίζει τη συμφωνία μεταξύ των ομάδων και της βάσης αλήθειας ως εξής:

$$RI = \frac{TP + TN}{TP + TN + FP + FN}$$

όπου TP είναι τα αληθώς θετικά, TN είναι τα αληθώς αρνητικά, FP είναι τα ψευδώς θετικά και FN είναι τα ψευδώς αρνητικά.

2. Καθορισμός του Αριθμού των Ομάδων

Ζήτημα:

Ο βέλτιστος αριθμός ομάδων (k) στην ομαδοποίηση είναι συχνά άγνωστος.

Επίπτωση:

Η υπερτίμηση ή υποτίμηση του k μπορεί να οδηγήσει σε κακές επιδόσεις ομαδοποίησης. Οι τεχνικές όπως η Μέθοδος του Αγκώνα (Elbow Method) και η Ανάλυση Σιλουέτας (Silhouette Method or analysis) (Rousseeuw, 1987) μπορούν να βοηθήσουν, αλλά δεν είναι πάντα καθοριστικές.

Μαθηματικό Μοντέλο:

Ο δείκτης σιλουέτας (S) υπολογίζεται ως:

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

όπου a είναι η μέση απόσταση μεταξύ ενός σημείου και άλλων σημείων στην ίδια ομάδα, και b είναι η μέση απόσταση μεταξύ του σημείου και των σημείων της κοντινότερης ομάδας.

3. Ερμηνευσιμότητα

Ζήτημα:

Τα μοντέλα μη εποπτευόμενης μάθησης, ειδικά τα πολύπλοκα όπως οι αυτοκωδικοποιητές, είναι δύσκολα προς ερμηνεία.

Επίπτωση:

Η έλλειψη ερμηνευσιμότητας περιορίζει την εμπιστοσύνη των χρηστών στα αποτελέσματα, περιορίζοντας την εφαρμογή τους σε τομείς που απαιτούν εξηγησιμότητα. (Lipton, 2016)

4. Κλιμακωσιμότητα

Ζήτημα:

Ορισμένοι αλγόριθμοι, όπως η ιεραρχική ομαδοποίηση, δεν κλιμακώνονται καλά με μεγάλα σύνολα δεδομένων.

Επίπτωση:

Οι υπολογιστικές απαιτήσεις αυξάνονται εκθετικά, καθιστώντας τους αλγόριθμους μη πρακτικούς για εφαρμογές μεγάλης κλίμακας. (Karypis & Han, 2000)

*5. Υψηλή Διαστασιμότητα***Ζήτημα:**

Τα δεδομένα υψηλής διάστασης μπορούν να αποκρύψουν πρότυπα.

Επίπτωση:

Οι αλγόριθμοι ενδέχεται να δυσκολεύονται να αναγνωρίσουν ουσιαστικές δομές, απαιτώντας τη χρήση τεχνικών μείωσης διαστάσεων, όπως η ανάλυση κυρίων συνιστωσών (PCA) (Jolliffe I. T., 2002), η οποία μπορεί να οδηγήσει σε απώλεια κρίσιμων πληροφοριών.

*6. Εξαγωγή Χαρακτηριστικών***Ζήτημα:**

Η μη εποπτευόμενη μάθηση απαιτεί σημαντική προσπάθεια στην εξαγωγή και επιλογή χαρακτηριστικών.

Επίπτωση:

Η διαδικασία είναι χρονοβόρα και απαιτεί εξειδικευμένη γνώση, η οποία μπορεί να επηρεάσει την απόδοση και τη γενίκευση του μοντέλου. (Guyon & Elisseeff, 2003)

*7. Ευαισθησία στον Θόρυβο και τους Εξωγενείς***Ζήτημα:**

Οι αλγόριθμοι μη εποπτευόμενης μάθησης επηρεάζονται αρνητικά από θορυβώδη δεδομένα.

Επίπτωση:

Αυτό μπορεί να οδηγήσει σε στρεβλωμένα αποτελέσματα και λανθασμένα συμπεράσματα. Η χρήση ανθεκτικών μεθόδων προεπεξεργασίας είναι κρίσιμη. (Hodge & Austin, 2004)

*8. Πολυπλοκότητα της Βελτιστοποίησης Υπερπαραμέτρων***Ζήτημα:**

Η προσεκτική βελτιστοποίηση υπερπαραμέτρων είναι απαραίτητη για πολλούς αλγόριθμους μη εποπτευόμενης μάθησης.

Επίπτωση:

Η αναζήτηση βέλτιστων υπερπαραμέτρων απαιτεί εκτενή πειραματισμό, επηρεάζοντας την απόδοση και τον χρόνο ανάπτυξης του μοντέλου. (Bergstra & Bengio, 2012)

Στρατηγικές για την Αντιμετώπιση των Προκλήσεων

1. Επικύρωση Μοντέλου

Η επικύρωση των μοντέλων είναι κρίσιμη για την αξιολόγηση της ποιότητας των ομάδων που παράγονται. Τεχνικές όπως οι δείκτες σιλουέτας $S = \frac{b-a}{\max(a,b)}$, όπου a είναι η μέση απόσταση από τα σημεία της ίδιας ομάδας και b η μέση απόσταση από τα σημεία της κοντινότερης ομάδας, παρέχουν μια ποσοτική μέτρηση της ποιότητας των ομάδων. Σημαντική είναι επίσης η χρήση της μεθόδου Davies-Bouldin:

$$DB = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} ((s_i + s_j)/d_{ij})$$

όπου s_i είναι η μέση εσωτερική απόσταση της ομάδας i και d_{ij} είναι η απόσταση μεταξύ των κέντρων των ομάδων i και j . (Davies & Bouldin, 1979)

Η εξωτερική επικύρωση μέσω γνωστών μετρήσεων (π.χ. Adjusted Rand Index) μπορεί να ενισχύσει την αξιοπιστία των αποτελεσμάτων. (Hubert & Arabie, 1985)

2. Εκτίμηση Βέλτιστων Ομάδων

Η εκτίμηση του βέλτιστου αριθμού ομάδων μπορεί να επιτευχθεί μέσω μεθόδων όπως η Μέθοδος του Αγκώνα. Αυτή η μέθοδος περιλαμβάνει την εκτίμηση της παραμέτρου k με βάση την εσωτερική διασπορά των ομάδων $W(k)$:

$$W(k) = \sum_{i=1}^k \sum_{x_j \in C_i} \|x_j - \mu_i\|^2$$

όπου μ_i είναι το κέντρο της ομάδας C_i . Η ανάλυση σιλουέτας μπορεί επίσης να χρησιμοποιηθεί για την επιλογή του k . (Rousseeuw, 1987)

3. Βελτίωση της Ερμηνευσιμότητας

Η ερμηνευσιμότητα των μοντέλων είναι κρίσιμη για την κατανόηση και την αποδοχή τους. Προτεινόμενες προσεγγίσεις περιλαμβάνουν τη χρήση απλών μοντέλων και εργαλείων οπτικοποίησης, καθώς και μετα-ερμηνευτικές μεθόδους, όπως οι τιμές

SHAP (Lundberg & Lee, 2017), που ποσοτικοποιούν την επίδραση κάθε χαρακτηριστικού στην πρόβλεψη του μοντέλου.

4. Ενίσχυση της Κλιμακωσιμότητας

Η κλιμακωσιμότητα μπορεί να επιτευχθεί μέσω παράλληλης επεξεργασίας και κατανομημένου υπολογισμού. Χρήση αλγορίθμων όπως το mini-batch K-means, όπου η ενημέρωση των κέντρων γίνεται με υποσύνολα των δεδομένων, συμβάλλει στην αποτελεσματική επεξεργασία μεγάλων συνόλων δεδομένων.

5. Διαχείριση Υψηλής Διαστασιμότητας

Η μείωση διαστάσεων μέσω τεχνικών όπως το PCA (Principal Component Analysis) και το t-SNE (t-Distributed Stochastic Neighbor Embedding) είναι ζωτικής σημασίας για τη διαχείριση της πολυπλοκότητας των δεδομένων (Hinton & Salakhutdinov, 2006). Αυτές οι μέθοδοι επιτρέπουν την οπτικοποίηση και ανάλυση υψηλής διαστασιμότητας δεδομένων με πιο κατανοητό τρόπο.

6. Αποτελεσματική Εξαγωγή Χαρακτηριστικών

Η αυτοματοποίηση της επιλογής χαρακτηριστικών μέσω τεχνικών όπως οι αλγόριθμοι γενετικής και η σημασία χαρακτηριστικών από μοντέλα (Random Forest, XGBoost) είναι κρίσιμη για τη βελτίωση της αποδοτικότητας. (Guyon & Elisseeff, 2003)

7. Διαχείριση Θορύβου και Εξωγενών

Η προεπεξεργασία δεδομένων μέσω καθαρισμού και κανονικοποίησης είναι απαραίτητη. Ανθεκτικοί αλγόριθμοι όπως το DBSCAN επιτρέπουν την ομαδοποίηση με λιγότερη ευαισθησία στον θόρυβο (Ester, Krieger, Sander, & Xu, 1996).

8. Βελτιστοποίηση Υπερπαραμέτρων

Η συστηματική βελτιστοποίηση των υπερπαραμέτρων μπορεί να επιτευχθεί μέσω μεθόδων όπως η αναζήτηση πλέγματος, η τυχαία αναζήτηση και η βελτιστοποίηση Bayesian (Snoek, Larochelle, & Adams, 2012). Χρησιμοποιώντας διασταυρούμενη επικύρωση, οι εκτιμήσεις σταθεροποιούνται, βελτιώνοντας την γενίκευση των μοντέλων.

Η αντιμετώπιση των προκλήσεων στην ομαδοποίηση δεδομένων απαιτεί μια συνδυαστική προσέγγιση που περιλαμβάνει τεχνικές, εργαλεία και μεθόδους επικύρωσης. Η ενσωμάτωση μαθηματικών μοντέλων και σύγχρονων αναφορών καθιστά τη διαδικασία πιο αξιόπιστη και αποτελεσματική. Η συνεχιζόμενη έρευνα και

οι καινοτόμες τεχνικές είναι απαραίτητες για τη βελτίωση της ποιότητας και της αποδοτικότητας των ομαδοποιήσεων.

Ενισχυτική Μάθηση (REINFORCEMENT LEARNING)

Η ενισχυτική μάθηση (Reinforcement Learning - RL) είναι ένας κλάδος της μηχανικής μάθησης όπου ένας πράκτορας μαθαίνει να λαμβάνει αποφάσεις μέσω δράσεων σε ένα περιβάλλον, με στόχο τη μεγιστοποίηση των σωρευτικών ανταμοιβών (Sutton & Barto, 2018). Σε αντίθεση με την επιβλεπόμενη μάθηση, η οποία βασίζεται σε δεδομένα με ετικέτες, η RL εστιάζει στις αλληλεπιδράσεις του πράκτορα με το περιβάλλον, που καθορίζονται από τις πολιτικές δράσης που αναπτύσσει.

Κύριες Έννοιες στην Ενισχυτική Μάθηση

1. **Πράκτορας (Agent):** Ο μαθητής ή ο λήπτης αποφάσεων, ο οποίος αλληλεπιδρά με το περιβάλλον.
2. **Περιβάλλον (Environment):** Το εξωτερικό σύστημα στο οποίο ο πράκτορας λειτουργεί, το οποίο μπορεί να έχει μεταβαλλόμενες καταστάσεις και κανόνες.
3. **Κατάσταση (S):** Μια αναπαράσταση της τρέχουσας κατάστασης του πράκτορα στο περιβάλλον.
4. **Δράση (A):** Το σύνολο όλων των δυνατών κινήσεων που μπορεί να κάνει ο πράκτορας.
5. **Ανταμοιβή (R):** Ένα σήμα ανάδρασης από το περιβάλλον που μπορεί να είναι θετικό ή αρνητικό.
6. **Πολιτική (π):** Μια στρατηγική που χρησιμοποιεί ο πράκτορας για να καθορίσει την επόμενη δράση με βάση την τρέχουσα κατάσταση.
7. **Συνάρτηση Αξίας (V):** Μια συνάρτηση που εκτιμά την αναμενόμενη σωρευτική ανταμοιβή από μια δεδομένη κατάσταση.
8. **Συνάρτηση Q (Q):** Μια συνάρτηση που εκτιμά την αναμενόμενη σωρευτική ανταμοιβή από ένα ζεύγος κατάστασης-δράσης.




Figure 11 Ενισχυτική Μάθηση

Μαθηματικά Μοντέλα

Διαδικασία Μαρκοβιανής Απόφασης (MDP)

Τα προβλήματα ενισχυτικής μάθησης συνήθως μοντελοποιούνται χρησιμοποιώντας μια Διαδικασία Μαρκοβιανής Απόφασης (Markov Decision Process - MDP), οριζόμενη από:

- S: Ένα πεπερασμένο σύνολο καταστάσεων.
- A: Ένα πεπερασμένο σύνολο δράσεων.
- $P(s'|s,a)$: Μεταβατική πιθανότητα από την κατάσταση s στην κατάσταση s' δεδομένης της δράσης a.
- $R(s,a)$: Ανταμοιβή που λαμβάνεται μετά τη λήψη της δράσης a στην κατάσταση s.
- γ : Παράγοντας έκπτωσης, $0 \leq \gamma < 1$, που καθορίζει τη σημασία των μελλοντικών ανταμοιβών. (Bellman, 1957)

Ο στόχος είναι να βρεθεί μια πολιτική π που μεγιστοποιεί την αναμενόμενη απόδοση (cumulative reward), οριζόμενη ως:

$$G_t = R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \dots = \sum_{k=0}^{\infty} \gamma^k R_{t+k+1}$$

Συνάρτηση Αξίας και Εξισώσεις Bellman

Η συνάρτηση αξίας κατάστασης $V^\pi(s)$ υπό μια πολιτική π ορίζεται ως η αναμενόμενη απόδοση ξεκινώντας από την κατάσταση s και ακολουθώντας την πολιτική π :

$$V^\pi(s) = E_\pi[G_t \mid S_t = s]$$

Η συνάρτηση αξίας δράσης $Q^\pi(s,a)$ ορίζεται ως η αναμενόμενη απόδοση ξεκινώντας από την κατάσταση s , λαμβάνοντας τη δράση a , και στη συνέχεια ακολουθώντας την πολιτική π :

$$Q^\pi(s, a) = E_\pi[G_t \mid S_t = s, A_t = a]$$

Η εξίσωση Bellman προσδοκίας για V^π είναι:

$$V^\pi = \sum_a \pi(a \mid s) \sum_{s'} P(s', s, a) [R(s, a) + \gamma V^\pi(s')]$$

Ομοίως, η εξίσωση Bellman προσδοκίας για το Q^π είναι:

$$Q^\pi(s, a) = \sum_{s'} P(s' \mid s, a) [R(s, a) + \gamma \sum_{a'} \pi(a', s') Q^\pi(s', a')]$$

Βέλτιστη Πολιτική και Εξισώσεις Βελτιστοποίησης Bellman

Η βέλτιστη πολιτική π^* μεγιστοποιεί τη συνάρτηση αξίας:

$$\pi^* = \operatorname{argmax}_\pi V^\pi(s)$$

Η βέλτιστη συνάρτηση αξίας $V^*(s)$ είναι :

$$V^*(s) = \max_\pi V^\pi(s)$$

Η εξίσωση βελτιστοποίησης Bellman για το V^* είναι:

$$V^*(s) = \max_a \sum_{s'} P(s', s, a) [R(s, a) + \gamma V^*(s')]$$

Η εξίσωση βελτιστοποίησης Bellman για το Q^* είναι:

$$Q^*(s, a) = \sum_{s'} P(s', s, a) [R(s, a) + \gamma \max_{a'} Q^*(s', a')]$$

Επίλυση Προβλημάτων Ενισχυτικής Μάθησης

Δυναμικός Προγραμματισμός

Οι μέθοδοι Δυναμικού Προγραμματισμού (Dynamic Programming - DP) όπως η Επανάληψη Αξίας (Value Iteration) και η Επανάληψη Πολιτικής (Policy Iteration) χρησιμοποιούνται όταν το μοντέλο του περιβάλλοντος, δηλαδή οι πιθανότητες μεταβάσεων και οι ανταμοιβές, είναι γνωστά. (Bertsekas & Tsitsiklis, 2016)

- **Επανάληψη Αξίας:** Ενημερώνει επαναληπτικά τη συνάρτηση αξίας χρησιμοποιώντας την εξίσωση βελτιστοποίησης Bellman.

$$V_{k+1}(s) = \max_a \sum_{s'} P(s' \mid s, a) [R(s, a) + \gamma V_k(s')]$$

- **Επανάληψη Πολιτικής:** Εναλλάσσεται μεταξύ αξιολόγησης πολιτικής (υπολογισμός του V^π) και βελτίωσης πολιτικής (ενημέρωση της πολιτικής χρησιμοποιώντας τη συνάρτηση αξίας). (Sutton & Barto, 2018)

Μέθοδοι Monte Carlo

Οι μέθοδοι Monte Carlo μαθαίνουν απευθείας από επεισόδια εμπειρίας χωρίς να απαιτούν μοντέλο του περιβάλλοντος. Αυτές οι μέθοδοι εκτιμούν την αξία των καταστάσεων ή των ζευγών κατάστασης-δράσης με βάση τον μέσο όρο των αποδόσεων που παρατηρούνται μετά την επίσκεψη σε αυτές τις καταστάσεις ή τη λήψη αυτών των δράσεων. (Degris, Pilarski, & Sutton, 2012)

Μάθηση Μέσω Χρονικών Διαφορών

Οι μέθοδοι μάθησης μέσω χρονικών διαφορών (Temporal-Difference - TD) συνδυάζουν ιδέες από τις μεθόδους Monte Carlo και τον Δυναμικό Προγραμματισμό. Ενημερώνουν τις εκτιμήσεις με βάση την πραγματική εμπειρία και τις υπάρχουσες εκτιμήσεις.

- **TD(0):** Η απλούστερη μέθοδος TD, ενημερώνει την αξία της τρέχουσας κατάστασης με βάση την παρατηρούμενη ανταμοιβή και την αξία της επόμενης κατάστασης.

$$V(S_t) \leftarrow V(S_t) + \alpha [R_{t+1} + \gamma V(S_{t+1}) - V(S_t)]$$

- **Q-Learning:** Ένας αλγόριθμος ελέγχου εκτός πολιτικής TD που επιδιώκει να βρει την βέλτιστη πολιτική.

$$Q(S_t, A_t) \leftarrow Q(S_t, A_t) + \alpha [R_{t+1} + \gamma \max_a Q(S_{t+1}, a) - Q(S_t, A_t)]$$

- **SARSA (State-Action-Reward-State-Action):** Ένας αλγόριθμος ελέγχου πολιτικής TD που ενημερώνει την τιμή Q με βάση τη δράση που πράγματι λήφθηκε από την πολιτική.

$$Q(S_t, A_t) \leftarrow Q(S_t, A_t) + \alpha [R_{t+1} + \gamma Q(S_{t+1}, A_{t+1}) - Q(S_t, A_t)]$$

(“Fuzzy Sarsa: An approach to fuzzifying Sarsa Learning - QMUL”)

Προσέγγιση Συνάρτησης

Για μεγάλους χώρους καταστάσεων ή δράσεων, οι μέθοδοι πίνακα δεν είναι εφικτές. Οι μέθοδοι προσέγγισης συνάρτησης όπως η Γραμμική Προσέγγιση, τα Νευρωνικά Δίκτυα και η Βαθιά Μάθηση χρησιμοποιούνται για να προσεγγίσουν τις συναρτήσεις αξίας.

- **Γραμμική Προσέγγιση:** Η συνάρτηση αξίας προσεγγίζεται ως ένας γραμμικός συνδυασμός χαρακτηριστικών. $V(s) \approx w^T \phi(s)$ όπου $\phi(s)$ είναι ένα διανύσμα χαρακτηριστικών που αναπαριστά την κατάσταση s και w είναι ένα διανύσμα βαρών. (Bertsekas & Tsitsiklis, 2016)
- **Νευρωνικά Δίκτυα:** Τα Δίκτυα Βαθιάς Q (Deep Q-Networks - DQN) χρησιμοποιούν νευρωνικά δίκτυα για να προσεγγίσουν τη συνάρτηση Q . Το δίκτυο εκπαιδεύεται χρησιμοποιώντας μια συνάρτηση απώλειας βασισμένη στο σφάλμα TD. (Mnih, Kavukcuoglu, Silver, Rummery, & Hassabis, 2015)

Q-Learning

Το Q-learning είναι ένας αλγόριθμος ενίσχυσης μάθησης χωρίς μοντέλο που στοχεύει να μάθει την ποιότητα των ενεργειών, υποδεικνύοντας σε έναν πράκτορα ποια ενέργεια να πάρει υπό ποιες συνθήκες. Το επιτυγχάνει αυτό μαθαίνοντας μια συνάρτηση, $Q(s,a)$, που εκτιμά την αναμενόμενη χρησιμότητα της λήψης μιας δεδομένης ενέργειας a σε μια δεδομένη κατάσταση s και ακολουθώντας την βέλτιστη πολιτική στη συνέχεια.

Βασικές Έννοιες

1. **Κατάσταση (s):** Η τρέχουσα κατάσταση ή διαμόρφωση στην οποία βρίσκεται ο πράκτορας.
2. **Ενέργεια (a):** Ένα σύνολο όλων των πιθανών κινήσεων που μπορεί να κάνει ο πράκτορας.
3. **Ανταμοιβή (r):** Άμεση επιστροφή που λαμβάνεται μετά τη μετάβαση από μία κατάσταση σε μία άλλη λόγω μιας ενέργειας.
4. **Πολιτική (π):** Η στρατηγική που χρησιμοποιεί ο πράκτορας για να καθορίσει την επόμενη ενέργεια με βάση την τρέχουσα κατάσταση.
5. **Τιμή- Q ($Q(s,a)$):** Η αναμενόμενη χρησιμότητα της λήψης της ενέργειας a σε κατάσταση s και ακολουθώντας την καλύτερη πολιτική στη συνέχεια.

Ο Αλγόριθμος Q-Learning

Το Q-learning ενημερώνει τις τιμές Q χρησιμοποιώντας την εξίσωση Bellman. Ο βασικός κανόνας ενημέρωσης είναι:

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

όπου:

- s είναι η τρέχουσα κατάσταση.
- a είναι η ενέργεια που λήφθηκε.
- r είναι η άμεση ανταμοιβή που λήφθηκε μετά τη λήψη της ενέργειας a .
- s' είναι η νέα κατάσταση μετά τη λήψη της ενέργειας a .
- α είναι ο ρυθμός εκμάθησης (πόσο η νέα πληροφορία υπερκαλύπτει την παλιά).
- γ είναι ο παράγοντας έκπτωσης (σημασία των μελλοντικών ανταμοιβών).

Βήματα του Q-Learning

1. **Αρχικοποίηση** του πίνακα $Q(s,a)$ αυθαίρετα.
2. **Παρατήρηση** της τρέχουσας κατάστασης s .
3. **Επιλογή** μιας ενέργειας a με βάση την τρέχουσα κατάσταση s χρησιμοποιώντας μια πολιτική που προκύπτει από το Q (π.χ. πολιτική ϵ -greedy).
4. **Εκτέλεση** της ενέργειας a και παρατήρηση της ανταμοιβής r και της επόμενης κατάστασης s' .
5. **Ενημέρωση** της τιμής- Q για το ζεύγος κατάστασης-ενέργειας (s, a) χρησιμοποιώντας τον κανόνα ενημέρωσης.
6. **Ορισμός** της νέας κατάστασης s' ως την τρέχουσα κατάσταση.
7. **Επανάληψη** της διαδικασίας μέχρι να επιτευχθεί η τελική κατάσταση (π.χ. επιτευχθεί μια κατάσταση στόχος).

Μαθηματικό Παράδειγμα

Ας θεωρήσουμε έναν απλό κόσμο πλέγματος όπου ένας πράκτορας μπορεί να κινηθεί προς τα πάνω, κάτω, αριστερά ή δεξιά. Ο πράκτορας ξεκινά από μια θέση και στοχεύει να φτάσει σε μια θέση στόχο όπου λαμβάνει υψηλή ανταμοιβή. Άλλες θέσεις μπορεί να έχουν διαφορετικές ανταμοιβές, συμπεριλαμβανομένων αρνητικών για εμπόδια.

Ας ορίσουμε τις παραμέτρους:

- $\alpha=0.1$ (ρυθμός εκμάθησης)
- $\gamma=0.9$ (παράγοντας έκπτωσης)

Παράδειγμα Βημάτων

1. **Αρχικοποίηση:** Ο πίνακας $Q(s, a)$ αρχικοποιείται στο μηδέν για όλα τα ζεύγη κατάστασης-ενέργειας.

2. **Επεισόδιο 1:**

- Ξεκινάμε στην κατάσταση s .
- Επιλέγουμε την ενέργεια a (ας πούμε ότι ο πράκτορας κινείται δεξιά).
- Υποθέτουμε ότι λαμβάνει ανταμοιβή $r=-1$ και μεταβαίνει στην κατάσταση s' .
- Ενημερώνουμε την τιμή- Q χρησιμοποιώντας τον τύπο:

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

Επειδή όλες οι τιμές Q είναι αρχικά μηδενικές, η ενημέρωση απλοποιείται σε:

$$Q(s, \text{δεξιά}) \leftarrow 0 + 0.1[-1 + 0] = -0.1$$

3. **Επόμενα Επεισόδια:** Ο πράκτορας συνεχίζει να εξερευνά το περιβάλλον, λαμβάνει ανταμοιβές και ενημερώνει τις τιμές- Q . Με την πάροδο του χρόνου, οι τιμές- Q θα συγκλίνουν στις αληθινές τιμές της βέλτιστης πολιτικής.

Οπτική Επίδειξη (Οπτικοποίηση)

Για να οπτικοποιήσουμε το Q-learning, μπορούμε να προσομοιώσουμε έναν πράκτορα που κινείται σε έναν κόσμο πλέγματος, ενημερώνοντας τις τιμές- Q και συγκλίνοντας προς μια βέλτιστη πολιτική. Αυτό μπορεί να υλοποιηθεί σε περιβάλλον matlab, όπως εξηγείται ακολούθως.

Παράδειγμα εφαρμογής της τεχνικής Q-learning στο προγραμματιστικό περιβάλλον του Matlab

Ας υλοποιήσουμε έναν απλό κόσμο πλέγματος και να οπτικοποιήσουμε τη διαδικασία εκμάθησης του πράκτορα. Το περιβάλλον θα είναι ένα πλέγμα 7×7 , και ο στόχος του πράκτορα είναι να φτάσει στον προορισμό που ορίζουμε εμείς με τον πιο αποδοτικό τρόπο(διαδρομή) αποφεύγοντας κάποια εμπόδια.

% Σενάριο για τη δημιουργία πλέγματος 7×7 και υλοποίηση του Q-learning

```

% Βήμα 1: Ρύθμιση του Περιβάλλοντος
gridSize = 7;
grid = zeros(gridSize);

% Ορισμός των θέσεων έναρξης και στόχου
startPos = [1, 1];
goalPos = [7, 7];

% Θέσπιση των θέσεων έναρξης και στόχου
grid(startPos(1), startPos(2)) = 1;
grid(goalPos(1), goalPos(2)) = 2;

% Ορισμός εμποδίων
obstacles = [1,2; 2,2;3, 3; 3, 4;4,1; 4, 3; 5, 5];
for i = 1:size(obstacles, 1)
    grid(obstacles(i, 1), obstacles(i, 2)) = -1;
end

% Βήμα 2: Αρχικοποίηση των Παραμέτρων του Q-learning
% Ορισμός ενεργειών: επάνω, κάτω, αριστερά, δεξιά
actions = [1, 2, 3, 4];
numActions = length(actions);

% Αρχικοποίηση του πίνακα Q με μηδενικά
Q = zeros(gridSize, gridSize, numActions);

% Παράμετροι μάθησης
alpha = 0.1;    % Ρυθμός μάθησης
gamma = 0.9;    % Παράγοντας έκπτωσης
epsilon = 1.0;  % Αρχικός ρυθμός εξερεύνησης
epsilonDecay = 0.995; % Παράγοντας μείωσης του epsilon
minEpsilon = 0.1; % Ελάχιστο epsilon
numEpisodes = 2000; % Αύξηση αριθμού επεισοδίων

```

```

% Βήμα 3: Αλγόριθμος Q-learning με Οπτικοποίηση
figure;
for episode = 1:numEpisodes
    % Αρχικοποίηση της θέσης εκκίνησης
    state = startPos;

    % Αποθήκευση της διαδρομής για οπτικοποίηση
    path = state;

    while ~isequal(state, goalPos)
        % Επιλογή ενέργειας με την πολιτική epsilon-greedy
        if rand < epsilon
            action = randi(numActions); % Εξερεύνηση
        else
            [~, action] = max(Q(state(1), state(2), :)); % Εκμετάλλευση
        end

        % Λήψη ενέργειας και παρατήρηση της επόμενης κατάστασης και ανταμοιβής
        [nextState, reward] = takeAction(state, action, grid);

        % Ενημέρωση της τιμής Q
        bestNextAction = max(Q(nextState(1), nextState(2), :));
        Q(state(1), state(2), action) = Q(state(1), state(2), action) + ...
            alpha * (reward + gamma * bestNextAction - Q(state(1), state(2), action));

        % Μετάβαση στην επόμενη κατάσταση
        state = nextState;

        % Προσθήκη στη διαδρομή
        path = [path; nextState];
    end

    % Μείωση του epsilon

```

```

epsilon = max(minEpsilon, epsilon * epsilonDecay);

% Οπτικοποίηση του τρέχοντος επεισοδίου
imagesc(grid);
colormap([1 1 1; 0 1 0; 1 0 0; 0 0 0]); (“colormap.colors — colormap 1.0.6
documentation - Read the Docs”)
hold on;
plot(path(:, 2), path(:, 1), 'b', 'LineWidth', 2);
plot(startPos(2), startPos(1), 'go', 'MarkerSize', 10, 'MarkerFaceColor', 'g');
plot(goalPos(2), goalPos(1), 'ro', 'MarkerSize', 10, 'MarkerFaceColor', 'r');
title(['Επεισόδιο: ', num2str(episode)]);
hold off;
drawnow;
pause(0.01); % Παύση για οπτικό εφέ
end

% Ορισμός Συναρτήσεων
function [nextState, reward] = takeAction(state, action, grid)
% Ορισμός ενεργειών: επάνω, κάτω, αριστερά, δεξιά
actions = [-1, 0; 1, 0; 0, -1; 0, 1];
nextState = state + actions(action, :);

% Εξασφάλιση ότι η επόμενη κατάσταση είναι εντός των ορίων
nextState = max(min(nextState, size(grid, 1)), 1);

% Καθορισμός ανταμοιβής
if isequal(nextState, [7, 7])
    reward = 10; % Ανταμοιβή για την επίτευξη του στόχου
elseif grid(nextState(1), nextState(2)) == -1
    reward = -10; % Ποινή για χτύπημα σε εμπόδιο
else
    reward = -2; % Μικρή ποινή για κάθε κίνηση
end
end
end

```


Επεξήγηση κώδικα Βήμα προς Βήμα

Ο παρακάτω κώδικας υλοποιεί τον αλγόριθμο Q-learning σε ένα πλέγμα διαστάσεων 7x7, όπου ο στόχος είναι να εκπαιδευτεί ένας πράκτορας (agent) να πλοηγείται από μια αρχική θέση σε μια τελική (στόχος) θέση, αποφεύγοντας τα εμπόδια που υπάρχουν στο περιβάλλον. Η ανάλυση του κώδικα και των αποτελεσμάτων θα πραγματοποιηθεί με ακαδημαϊκή προσέγγιση, εστιάζοντας στις παραμέτρους του Q-learning, τη διαδικασία μάθησης, και την οπτικοποίηση των αποτελεσμάτων.

1. Ρύθμιση του Περιβάλλοντος

1.1 Δημιουργία Πλέγματος

Matlab

```
gridSize = 7;
```

```
grid = zeros(gridSize);
```

Ένα πλέγμα διαστάσεων 7x7 δημιουργείται αρχικά γεμάτο με μηδενικές τιμές. Αυτός ο πίνακας θα χρησιμοποιηθεί για να αναπαραστήσει την κατάσταση του περιβάλλοντος, όπου οι διάφορες θέσεις θα αντιπροσωπεύουν διαφορετικά στοιχεία (π.χ. αρχική θέση, στόχος, εμπόδια).

1.2 Ορισμός Θέσεων

Matlab

```
startPos = [1, 1];
```

```
goalPos = [7, 7];
```

```
grid(startPos(1), startPos(2)) = 1;
```

```
grid(goalPos(1), goalPos(2)) = 2;
```

Η αρχική θέση του πράκτορα ορίζεται στην κορυφή αριστερά του πλέγματος (1,1) και η θέση του στόχου στην κάτω δεξιά γωνία (7,7). Οι θέσεις αυτές αναπαρίστανται με τις τιμές 1 και 2 στο πλέγμα, αντίστοιχα.

1.3 Ορισμός Εμποδίων

Matlab

```
obstacles = [1,2; 2,2;3, 3; 3, 4;4,1; 4, 3; 5, 5];
```

```

for i = 1:size(obstacles, 1)
    grid(obstacles(i, 1), obstacles(i, 2)) = -1;
end

```

Ο πίνακας `obstacles` καθορίζει τις θέσεις των εμποδίων που εμποδίζουν την κίνηση του πράκτορα. Οι θέσεις αυτές αποκτούν την τιμή -1 στο πλέγμα, υποδεικνύοντας ότι ο πράκτορας δεν μπορεί να περάσει από αυτές.

2. Αρχικοποίηση των Παραμέτρων του Q-learning

2.1 Ενέργειες

Matlab

```

actions = [1, 2, 3, 4]; % 1: επάνω, 2: κάτω, 3: αριστερά, 4: δεξιά
numActions = length(actions);

```

Ο πράκτορας έχει τέσσερις δυνατότητες κίνησης, οι οποίες αναπαρίστανται με αριθμούς. Η μεταβλητή `numActions` αποθηκεύει τον αριθμό των διαθέσιμων ενεργειών.

2.2 Αρχικοποίηση του Πίνακα Q

Matlab

```

Q = zeros(gridSize, gridSize, numActions);

```

Ο πίνακας `Q` αρχικοποιείται με μηδενικές τιμές. Ο πίνακας αυτός θα χρησιμοποιηθεί για να αποθηκεύσει τις εκτιμήσεις της ποιότητας των ενεργειών (Q-values) για κάθε κατάσταση και ενέργεια.

2.3 Ρυθμίσεις Μάθησης

Matlab

```

alpha = 0.1; % Ρυθμός μάθησης
gamma = 0.9; % Παράγοντας έκπτωσης
epsilon = 1.0; % Αρχικός ρυθμός εξερεύνησης
epsilonDecay = 0.995; % Παράγοντας μείωσης του epsilon
minEpsilon = 0.1; % Ελάχιστο epsilon
numEpisodes = 2000; % Αριθμός επεισοδίων

```

- **Ρυθμός Μάθησης (α):** Καθορίζει πόσο γρήγορα ο πράκτορας προσαρμόζει τις εκτιμήσεις του.
- **Παράγοντας Έκπτωσης (γ):** Καθορίζει τη σημασία των μελλοντικών ανταμοιβών. Τιμές κοντά στο 1 υποδηλώνουν ότι οι μελλοντικές ανταμοιβές είναι σημαντικές.
- **Epsilon (ϵ):** Ρυθμός εξερεύνησης, που καθορίζει την πιθανότητα του πράκτορα να επιλέξει τυχαία μια ενέργεια (εξερεύνηση) αντί να επιλέξει την καλύτερη γνωστή (εκμετάλλευση).
- **Epsilon Decay:** Ο ρυθμός μείωσης του epsilon, που επιτρέπει στον πράκτορα να εξερευνά λιγότερο με την πάροδο του χρόνου.
- **Αριθμός Επεισοδίων:** Ο συνολικός αριθμός επεισοδίων που θα εκτελεστεί κατά τη διάρκεια της εκπαίδευσης.

3. Αλγόριθμος Q-learning με Οπτικοποίηση

3.1 Εκπαίδευση

matlab

```
for episode = 1:numEpisodes
```

```
    state = startPos;
```

```
    path = state; % Αποθήκευση διαδρομής
```

Ο αλγόριθμος εκτελεί 2000 επεισόδια, όπου σε κάθε επεισόδιο ο πράκτορας ξεκινά από την αρχική του θέση και η διαδρομή του αποθηκεύεται για οπτικοποίηση.

3.2 Επιλογή Ενέργειας

matlab

```
if rand < epsilon
```

```
    action = randi(numActions); % Εξερεύνηση
```

```
else
```

```
    [~, action] = max(Q(state(1), state(2), :)); % Εκμετάλλευση
```

```
end
```

Η επιλογή της ενέργειας γίνεται μέσω της πολιτικής epsilon-greedy, όπου ο πράκτορας επιλέγει τυχαία μια ενέργεια με πιθανότητα epsilon και εκμεταλλεύεται την καλύτερη γνωστή ενέργεια σε αντίθετη περίπτωση.

3.3 Ενημέρωση του Πίνακα Q

matlab

```
[nextState, reward] = takeAction(state, action, grid);
```

```
bestNextAction = max(Q(nextState(1), nextState(2), :));
```

```
Q(state(1), state(2), action) = Q(state(1), state(2), action) + ...
```

```
alpha * (reward + gamma * bestNextAction - Q(state(1), state(2), action));
```

Ο πράκτορας εκτελεί την επιλεγμένη ενέργεια, υπολογίζει την επόμενη κατάσταση και την ανταμοιβή. Στη συνέχεια, η τιμή Q ενημερώνεται με βάση την εξίσωση Q-learning:

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

όπου s είναι η τρέχουσα κατάσταση, a είναι η ενέργεια, r είναι η ανταμοιβή, και s' είναι η επόμενη κατάσταση.

3.4 Μείωση του Epsilon

matlab

```
epsilon = max(minEpsilon, epsilon * epsilonDecay);
```

Η τιμή του epsilon μειώνεται με την πάροδο του χρόνου, επιτρέποντας στον πράκτορα να εξερευνά λιγότερο και να εκμεταλλεύεται περισσότερα τις γνωστές πληροφορίες.

3.5 Οπτικοποίηση

matlab

```
imagesc(grid);
```

```
colormap([1 1 1; 0 1 0; 1 0 0; 0 0 0]); ("colormap.colors — colormap 1.0.6  
documentation - Read the Docs")
```

```
hold on;
```

```
plot(path(:, 2), path(:, 1), 'b', 'LineWidth', 2);
```

```
plot(startPos(2), startPos(1), 'go', 'MarkerSize', 10, 'MarkerFaceColor', 'g');
```

```
plot(goalPos(2), goalPos(1), 'ro', 'MarkerSize', 10, 'MarkerFaceColor', 'r');
```

```
title(['Επεισόδιο: ', num2str(episode)]);
```

```
hold off;
```

```
drawnow;
```

```
pause(0.01);
```

Η οπτικοποίηση γίνεται σε κάθε επεισόδιο, επιτρέποντας την παρακολούθηση της προόδου του πράκτορα. Το πλέγμα αναπαρίσταται με διαφορετικά χρώματα για τις διάφορες καταστάσεις: λευκό (κενές θέσεις), πράσινο (θέση εκκίνησης), κόκκινο (στόχος) και μαύρο (εμπόδια).

4. Συναρτήσεις

4.1 takeAction

```
matlab
```

```
function [nextState, reward] = takeAction(state, action, grid)
```

```
    actions = [-1, 0; 1, 0; 0, -1; 0, 1];
```

```
    nextState = state + actions(action, :);
```

```
    nextState = max(min(nextState, size(grid, 1)), 1)
```

```
    if isequal(nextState, [7, 7])
```

```
        reward = 10; % Ανταμοιβή για την επίτευξη του στόχου
```

```
    elseif grid(nextState(1), nextState(2)) == -1
```

```
        reward = -10; % Ποινή για χτύπημα σε εμπόδιο
```

```
    else
```

```
        reward = -2; % Μικρή ποινή για κάθε κίνηση
```

```
    end
```

```
end
```

Αυτή η συνάρτηση διαχειρίζεται την εκτέλεση της επιλεγμένης ενέργειας. Υπολογίζει την επόμενη κατάσταση με βάση την τρέχουσα θέση και την επιλεγμένη ενέργεια. Αν η νέα κατάσταση είναι η θέση του στόχου, ο πράκτορας λαμβάνει ανταμοιβή 10. Σε περίπτωση που ο πράκτορας χτυπήσει σε εμπόδιο, λαμβάνει ποινή -10. Σε κάθε άλλη περίπτωση, η ποινή για την κίνηση είναι -2.

Διευκρινήσεις

Να σημειώσουμε εδώ ότι λόγο του ότι θέλαμε ο αλγόριθμος να διαλέγει την πιο αποδοτική διαδρομή. Ο παρεχόμενος αλγόριθμος Q-learning ενδέχεται να μην βρίσκει πάντα την πιο αποδοτική διαδρομή προς τον στόχο για διάφορους λόγους:

1. **Εξερεύνηση vs. Εκμετάλλευση:** Ο αλγόριθμος χρησιμοποιεί μια στρατηγική epsilon-greedy, που σημαίνει ότι μερικές φορές εξερευνά τυχαίες ενέργειες αντί να επιλέγει πάντα την βέλτιστη ενέργεια. Αυτή η εξερεύνηση βοηθά στη μάθηση αλλά μπορεί να οδηγήσει σε υπο-βέλτιστες διαδρομές κατά τη διάρκεια της εκπαίδευσης.
2. **Ρυθμός Μάθησης και Παράγοντας Έκπτωσης:** Οι επιλεγμένες τιμές για τον ρυθμό μάθησης (α) και τον παράγοντα έκπτωσης (γ) μπορούν να επηρεάσουν σημαντικά την ταχύτητα και την αποτελεσματικότητα με την οποία ο αλγόριθμος μαθαίνει την βέλτιστη διαδρομή.
3. **Αριθμός Επεισοδίων:** Ο αριθμός των επεισοδίων εκπαίδευσης (numEpisodes) μπορεί να μην είναι επαρκής για να συγκλίνει πλήρως ο αλγόριθμος στην βέλτιστη πολιτική.

Για να βελτιώσετε την πιθανότητα εύρεσης της πιο αποδοτικής διαδρομής, εξετάσαμε τις παρακάτω προσαρμογές:

1. **Μείωση του Epsilon με την Πάροδο του Χρόνου:** Μειώσαμε σταδιακά την τιμή του epsilon με την πάροδο του χρόνου για να μειώσουμε την εξερεύνηση καθώς ο πράκτορας μαθαίνει περισσότερο για το περιβάλλον.
2. **Αύξηση του Αριθμού Επεισοδίων:** Εκπαιδεύσαμε τον πράκτορα για περισσότερα επεισόδια για να επιτρέψουμε περισσότερο χρόνο για μάθηση.
3. **Ρύθμιση Υπερπαραμέτρων:** Πειραματιστήκαμε με διαφορετικές τιμές για το α και το γ για να βρούμε τον καλύτερο συνδυασμό για το συγκεκριμένο περιβάλλον.

Αποτελέσματα προσομοίωσης




Figure 12 Αποτέλεσμα matlab

Συμπεράσματα

Η εκπαίδευση του πράκτορα μέσω του αλγορίθμου Q-learning σε 2000 επεισόδια οδηγεί σε μια διαδρομή που ελαχιστοποιεί τις ποινές και μεγιστοποιεί τις ανταμοιβές. Ο πράκτορας μαθαίνει σταδιακά να αποφεύγει τα εμπόδια και να προσεγγίζει την τελική θέση με τις λιγότερες δυνατές κινήσεις.

- **Συμπεριφορά:** Καθώς ο αριθμός των επεισοδίων αυξάνεται, η πολιτική του πράκτορα βελτιώνεται, καθώς οι εκτιμήσεις Q γίνονται πιο αξιόπιστες. Σταδιακά, η εξερεύνηση μειώνεται και η εκμετάλλευση των γνώσεων του πράκτορα ενισχύεται.
- **Οπτική Απεικόνιση:** Η γραφική απεικόνιση της διαδρομής του πράκτορα στο πλέγμα δείχνει την πρόοδο και τη βελτίωση της απόδοσής του κατά τη διάρκεια της εκπαίδευσης.

Δίκτυα 5G

Εισαγωγή

Η πέμπτη γενιά (5G) των ασύρματων δικτύων αντιπροσωπεύει μια σημαντική εξέλιξη στον τομέα των παγκόσμιων επικοινωνιών, με ευρείες επιπτώσεις σε τομείς όπως η οικονομία, η τεχνολογία και η κοινωνία. Με χαρακτηριστικά που περιλαμβάνουν αυξημένες ταχύτητες, χαμηλή καθυστέρηση και μαζική συνδεσιμότητα, το 5G υπόσχεται να επιφέρει δραστικές βελτιώσεις στις επικοινωνίες και τις αλληλεπιδράσεις μας. Η ανάλυση αυτή εξετάζει τις τεχνικές βάσεις του 5G, τις εφαρμογές του σε νέες τεχνολογίες και τις προκλήσεις και επιπτώσεις που αυτό ενέχει.

Ενίσχυση Επικοινωνίας και Συνδεσιμότητας

Η τεχνολογία 5G διακρίνεται από την υψηλή ταχύτητα δεδομένων (data rate), την εξαιρετικά χαμηλή καθυστέρηση και την ενισχυμένη διασυνδεσιμότητα. Οι τρεις αυτές παράμετροι μπορούν να περιγράφουν μαθηματικά και να εξεταστούν σε σχέση με τις εφαρμογές και τα πλεονεκτήματα του 5G.

Ταχύτητα Δεδομένων (Data Rate)

Οι ταχύτητες δεδομένων στα δίκτυα 5G μπορούν να περιγράφουν μέσω της θεωρίας Shannon-Hartley, που ορίζει το όριο της ικανότητας του καναλιού επικοινωνίας. Η εξίσωση του Shannon για τη χωρητικότητα C του καναλιού είναι:

$$C = B * \log_2 \left(1 + \frac{S}{N} \right)$$

όπου:

- C είναι η χωρητικότητα του καναλιού σε bps (bits per second),
- B είναι το εύρος ζώνης του καναλιού σε Hz,
- S είναι η ισχύς του σήματος και
- N είναι η ισχύς του θορύβου.

Στα δίκτυα 5G, το εύρος ζώνης είναι κατά πολύ μεγαλύτερο από τα προηγούμενα δίκτυα (4G), που σημαίνει ότι η χωρητικότητα αυξάνεται εκθετικά, διευκολύνοντας

εφαρμογές που απαιτούν υψηλή ροή δεδομένων, όπως η ανάλυση δεδομένων σε πραγματικό χρόνο. (Zhou, Fang, & Yao, 2020)

Καθυστέρηση (Latency)

Η υπερ-χαμηλή καθυστέρηση αποτελεί κριτήριο για εφαρμογές σε πραγματικό χρόνο, όπως αυτόνομα οχήματα και χειρουργική εξ αποστάσεως. Η καθυστέρηση σε ένα δίκτυο μπορεί να περιγραφεί ως το άθροισμα του χρόνου μεταφοράς πακέτου και του χρόνου προώθησης:

$$Latency = Propagation Time + Transmission Time$$

$$\text{Καθυστέρηση} = \text{Χρόνος Διάδοσης} + \text{Χρόνος Μετάδοσης}$$

όπου ο χρόνος προώθησης υπολογίζεται μέσω της ταχύτητας διάδοσης του σήματος σε συνάρτηση με την απόσταση και η καθυστέρηση εξαρτάται άμεσα από τον τρόπο διεύθυνσης του καναλιού (Tariq, et al., 2021). Στα δίκτυα 5G, η μείωση του χρόνου αναμονής οφείλεται σε πιο αποδοτική χρήση των πόρων φάσματος και στη χρήση δικτύων μικροκυψέλης (small cells).

Διασυνδεσιμότητα Συσκευών

Η μαζική διασυνδεσιμότητα επιτρέπει την επέκταση του Διαδικτύου των Πραγμάτων (IoT), υποστηρίζοντας έναν μεγάλο αριθμό συσκευών ανά τετραγωνικό χιλιόμετρο. Το πρότυπο 5G, μέσα από την αρχιτεκτονική URLLC (Ultra-Reliable Low Latency Communication), επιτρέπει τη διαχείριση αυτών των συσκευών μέσω ενός πολυπλέκτη OFDMA (Orthogonal Frequency Division Multiple Access) για την υποστήριξη ταυτόχρονων ροών δεδομένων. (Park, Lee, & Kim, 2021)

Εφαρμογές του 5G

Η τεχνολογία 5G είναι σε θέση να μετασχηματίσει πολυάριθμους τομείς της καθημερινής ζωής και της οικονομίας, επηρεάζοντας σημαντικά τόσο την τεχνολογία όσο και την κοινωνία. Οι παρακάτω εφαρμογές εξετάζονται υπό το πρίσμα της νέας αυτής τεχνολογίας με έμφαση στις τεχνικές και κοινωνικοοικονομικές της διαστάσεις.

Υγεία

Η υψηλής ταχύτητας και χαμηλής καθυστέρησης συνδεσιμότητα του 5G προσφέρει νέες δυνατότητες στην υγειονομική περίθαλψη. Με την τηλεϊατρική, η συνδεσιμότητα

αυτή επιτρέπει την απομακρυσμένη παρακολούθηση ασθενών, ακόμη και την πραγματοποίηση ρομποτικών χειρουργικών επεμβάσεων σε πραγματικό χρόνο. Οι εφαρμογές αυτές βασίζονται σε αρχιτεκτονικές URLLC (Ultra-Reliable Low Latency Communication), οι οποίες διασφαλίζουν εξαιρετικά χαμηλές καθυστερήσεις και αξιόπιστη απόκριση του δικτύου, γεγονός που είναι καθοριστικό για την υγεία. (Chen, Yu, & Li, 2021) Τα δεδομένα για την παρακολούθηση ασθενών μπορούν να μοντελοποιηθούν χρησιμοποιώντας εξισώσεις ροής πακέτων σε πραγματικό χρόνο:

$$Packet\ Flow\ Rate = \frac{Total\ Data}{Latency} \cdot Reliability\ Factor$$

$$Ρυθμός\ Ροής\ Πακέτων = \frac{Συνολικά\ Δεδομένα}{(Καθυστέρηση \cdot Παράγοντας\ Αξιοπιστίας)}$$

Η εξίσωση αυτή περιγράφει την ταχύτητα ροής των δεδομένων σε περιβάλλοντα απομακρυσμένης υγείας, επιτρέποντας έγκαιρες ιατρικές παρεμβάσεις και βελτιώνοντας την ποιότητα των υπηρεσιών υγείας. (Sun, Huang, & Wang, 2022)

Μεταφορές

Η 5G υποστηρίζει την επικοινωνία V2X (Vehicle-to-Everything), επιτρέποντας στα οχήματα να επικοινωνούν σε πραγματικό χρόνο μεταξύ τους και με τις υποδομές, κρίσιμος παράγοντας για την ανάπτυξη αυτόνομων οχημάτων και έξυπνων συστημάτων κυκλοφορίας. Η τεχνολογία αυτή βασίζεται σε πολυπλέκτη OFDM (Orthogonal Frequency Division Multiplexing) για τη βελτιστοποίηση της διάχυσης σημάτων σε μεγάλα αστικά περιβάλλοντα, κάτι που μπορεί να αναπαρασταθεί μαθηματικά ως:

$$Signal\ Strength_{V2X} = OFDM_{capacity} \cdot Signal-to-Noise\ Ratio$$

$$Ισχύς\ Σήματος\ V2X = Χωρητικότητα\ OFDM \cdot Λόγος\ Σήματος\ προς\ Θόρυβο\ (Signal-to-Noise\ Ratio)$$

Με τον τρόπο αυτό διασφαλίζεται η αξιοπιστία και η ταχύτητα της επικοινωνίας σε απαιτητικά περιβάλλοντα. Τα οφέλη περιλαμβάνουν βελτιωμένη ασφάλεια, μείωση συμφόρησης και βελτιστοποίηση της κυκλοφορίας σε αστικά κέντρα. (Li, Gao, & Wu, 2023)

Βιομηχανία

Στη βιομηχανία, η τεχνολογία 5G υποστηρίζει το Βιομηχανικό Διαδίκτυο των Πραγμάτων (IIoT), με εφαρμογές που περιλαμβάνουν την παρακολούθηση σε πραγματικό χρόνο, την προληπτική συντήρηση και την αυτοματοποίηση. Η χρήση αισθητήρων που μεταδίδουν δεδομένα σε πραγματικό χρόνο σε δίκτυα 5G αυξάνει την παραγωγικότητα και μειώνει το χρόνο διακοπής των βιομηχανικών μηχανημάτων. Η παραγωγικότητα βελτιστοποιείται μέσω της εξίσωσης:

$$Productivity_{IIoT} = \frac{Operational\ Uptime}{Downtime\ Reduction\ Factor}$$

$$Παραγωγικότητα_{IIoT} = Χρόνος\ Λειτουργίας / (Παράγοντας\ Μείωσης\ Χρόνου\ Αδράνειας)$$

Η εφαρμογή αυτή υποστηρίζει τη βιομηχανική αποδοτικότητα και την καινοτομία στη διαχείριση πόρων και στην παραγωγή. (Wang, Zhang, & Tan, 2021)

Ψυχαγωγία και Μέσα Ενημέρωσης

Η 5G θα αναδιαμορφώσει τη βιομηχανία της ψυχαγωγίας, καθιστώντας δυνατές καθηλωτικές εμπειρίες επαυξημένης (AR) και εικονικής πραγματικότητας (VR), με τη βελτιστοποίηση της ροής δεδομένων και της αλληλεπίδρασης των χρηστών. Οι τεχνολογίες AR και VR υποστηρίζονται από τη χωρητικότητα του δικτύου, η οποία μπορεί να μοντελοποιηθεί ως:

$$Streaming\ Quality = Bandwidth \cdot \frac{Packet\ Delivery\ Rate}{Latency}$$

$$Ποιότητα\ Ροής = Εύρος\ Ζώνης \cdot Ρυθμός\ Παράδοσης\ Πακέτων / Καθυστέρηση$$

Η υψηλή αυτή ποιότητα δικτύου εξασφαλίζει απρόσκοπτες εμπειρίες και τη δυνατότητα για νέες μορφές διαδραστικού περιεχομένου. (Kim, Park, & Lee, 2022)

Η τεχνολογία 5G αντιπροσωπεύει ένα σημαντικό άλμα προς τα εμπρός στην εξέλιξη της επικοινωνίας, χαρακτηριζόμενη από πρωτοφανείς ταχύτητες, συνδεσιμότητα και δυνατότητες καινοτομίας. Ο μετασχηματιστικός της αντίκτυπος θα γίνει αισθητός σε διάφορους τομείς, αναμορφώνοντας τον τρόπο που αλληλοεπιδρούμε με την τεχνολογία και μεταξύ μας. Ενώ παραμένουν προκλήσεις στην ανάπτυξη και την ασφάλεια, τα οφέλη της 5G είναι έτοιμα να υπερτερούν αυτών των εμποδίων, προαναγγέλλοντας ένα μέλλον απρόσκοπτης, στιγμιαίας επικοινωνίας. Καθώς

συνεχίζουμε να εξερευνούμε και να αξιοποιούμε τις δυνατότητες της 5G, ο ρόλος της στη διαμόρφωση του μέλλοντος της επικοινωνίας θα γίνει όλο και πιο σημαντικός, οδηγώντας την πρόοδο και ενισχύοντας την παγκόσμια συνδεσιμότητα.

Προκλήσεις και Σκέψεις για την Τεχνολογία 5G

Η εφαρμογή της 5G προϋποθέτει την αντιμετώπιση διαφόρων προκλήσεων, οι οποίες σχετίζονται με την υποδομή, το φάσμα, την ασφάλεια και την υγεία, απαιτώντας μια πολυδιάστατη προσέγγιση.

Υποδομές και Κόστος

Η υλοποίηση της 5G απαιτεί σημαντικές επενδύσεις σε υποδομές, περιλαμβάνοντας εγκατάσταση νέων σταθμών βάσης, μικρών κυψελών και δικτύων οπτικών ινών, αυξάνοντας το οικονομικό βάρος (Choudhury, Singh, & Wang, 2021). Το κόστος ανάπτυξης μπορεί να μοντελοποιηθεί μέσω της εξίσωσης:

$$\text{Total Cost}_{5G} = \text{Cost}_{\text{Base Stations}} + \text{Cost}_{\text{Small Cells}} + \text{Cost}_{\text{Fiber Networks}}$$

$$\text{Συνολικό Κόστος 5G} = \text{Κόστος Βασικών Σταθμών} + \text{Κόστος Μικρών Κυψελών} + \text{Κόστος Δικτύων Οπτικών Ινών}$$

Αυτό αποτελεί σημαντικό εμπόδιο, ιδίως σε περιοχές με χαμηλή οικονομική απόδοση, καθώς απαιτείται προσαρμοσμένη υποστήριξη από την πολιτεία και τον ιδιωτικό τομέα.

Κατανομή Φάσματος

Η διαχείριση του φάσματος είναι κρίσιμη για την αποδοτική λειτουργία της 5G. Οι ρυθμιστικές αρχές πρέπει να επιτύχουν μια ισορροπία μεταξύ των αναγκών των εμπλεκόμενων μερών και της αποφυγής παρεμβολών, χρησιμοποιώντας εξισώσεις διαχείρισης φάσματος όπως:

$$\text{Spectrum Efficiency} = \frac{\text{Data Throughput}}{\text{Frequency Bandwidth}}$$

$$\text{Αποδοτικότητα Φάσματος} = \text{Ροή Δεδομένων} / \text{Εύρος Ζώνης Συχνότητας}$$

Η αποδοτική χρήση του φάσματος αυξάνει την απόδοση και την αξιοπιστία των δικτύων 5G, επιτρέποντας παράλληλα σε διαφορετικές εφαρμογές να συνυπάρχουν. (Li & Zhang, Spectrum allocation strategies in 5G: Balancing efficiency and fairness, 2022)

Ασφάλεια και Ιδιωτικότητα

Η φύση των δικτύων 5G επιτρέπει μεγαλύτερη διασυνδεσιμότητα, αυξάνοντας την πιθανότητα κυβερνοεπιθέσεων. Η διαχείριση της ασφάλειας μπορεί να αναπαρασταθεί με τη χρήση μαθηματικών μοντέλων ανίχνευσης επιθέσεων, όπως:

$$\text{Security Threat Detection Rate} = \frac{\text{Identified Threats}}{\text{Total Network Traffic}}$$

Ρυθμός Ανίχνευσης Απειλών Ασφάλειας = Αναγνωρισμένες Απειλές / Συνολική Κίνηση Δικτύου

Τα μοντέλα αυτά εξασφαλίζουν ότι εντοπίζονται και αντιμετωπίζονται πιθανές παραβιάσεις δεδομένων και επιθέσεις, προστατεύοντας την ιδιωτικότητα των χρηστών. (Lee, Kim, & Yoon, 2023)

Ανησυχίες για την Υγεία

Η δημόσια ανησυχία για τις επιπτώσεις της ακτινοβολίας των κυμάτων χιλιοστών της 5G απαιτεί αυστηρή επιστημονική έρευνα. Η επίδραση της ακτινοβολίας μπορεί να μοντελοποιηθεί χρησιμοποιώντας την εξίσωση απορρόφησης ενέργειας:

$$\text{Specific Absorption Rate (SAR)} = \frac{\text{Power Absorbed}}{\text{Tissue Mass}}$$

Συγκεκριμένος Ρυθμός Απορρόφησης (SAR) = Ισχύς που Απορροφάται / Μάζα Ιστού

Αυτό το μέτρο χρησιμοποιείται για την αξιολόγηση της ασφάλειας και της συμμόρφωσης με τα υγειονομικά πρότυπα. (Brown, Lee, & Tran, 2022)

Ευρύτερες Κοινωνικές και Οικονομικές Επιπτώσεις της 5G

Η 5G αναμένεται να επιφέρει σημαντικές επιπτώσεις στην κοινωνία και την οικονομία, ενισχύοντας την καινοτομία και την ψηφιακή ένταξη.

Οικονομική Ανάπτυξη

Η 5G προωθεί την οικονομική ανάπτυξη, συμβάλλοντας στην αύξηση της παραγωγικότητας και της ανταγωνιστικότητας. Η παραγωγικότητα μπορεί να εκτιμηθεί μέσω του τύπου:

$$\text{Economic Impact}_{5G} = \text{Productivity}_{\text{Sector}} \cdot \text{Efficiency Gain Factor}$$

$$\text{Οικονομικός Αντίκτυπος 5G} = \text{Παραγωγικότητα Τομέα} \cdot \text{Παράγοντας Κέρδους Απόδοσης}$$

Οι τεχνολογικές καινοτομίες αυξάνουν την αποδοτικότητα σε τομείς όπως οι τηλεπικοινωνίες, οι μεταφορές και η βιομηχανία, δημιουργώντας νέες επιχειρηματικές ευκαιρίες. (Wang, Zhang, & Tan, 2021)

Ψηφιακή Ένταξη

Η 5G ενδυναμώνει τις κοινότητες και διευκολύνει την πρόσβαση στο διαδίκτυο, γεφυρώνοντας το ψηφιακό χάσμα. Η ένταξη αυτή μπορεί να αναπαρασταθεί μαθηματικά ως:

$$\text{Digital Inclusion Rate} = \frac{\text{Connected Population}}{\text{Total Population}} \cdot 100\%$$

$$\text{Ρυθμός Ψηφιακής Συμπερίληψης} = (\text{Συνδεδεμένος Πληθυσμός} / \text{Συνολικός Πληθυσμός}) \cdot 100\%$$

Το υψηλό ποσοστό συνδεσιμότητας σε απομακρυσμένες περιοχές ενισχύει την πρόσβαση στην εκπαίδευση και τις υπηρεσίες υγείας, προωθώντας τη συνολική ανάπτυξη. (Chen & Kim, 2023)

Κοινωνικός Αντίκτυπος

Η 5G συμβάλλει στην επίτευξη στόχων βιώσιμης ανάπτυξης με την παροχή πρόσβασης σε υγεία, εκπαίδευση και άλλες δημόσιες υπηρεσίες. Ο κοινωνικός αντίκτυπος αυτής της τεχνολογίας μπορεί να εκτιμηθεί με το μοντέλο:

$$\text{Social Impact Index}_{5G} = \text{Access to Services} \times \text{Service Quality Enhancement}$$

$$\text{Δείκτης Κοινωνικού Αντίκτυπου 5G} = \text{Πρόσβαση σε Υπηρεσίες} \times \text{Βελτίωση Ποιότητας Υπηρεσιών}$$

Οι εφαρμογές αυτές συμβάλλουν στη βελτίωση της ποιότητας ζωής και προωθούν την κοινωνική πρόοδο μέσω καινοτόμων λύσεων. (Zhang, Wu, & Li, 2023)

Δομή και Συστατικά ενός Δικτύου 5G

Η τεχνολογία 5G βασίζεται σε πολυεπίπεδη υποδομή και τεχνολογίες που συνεργάζονται για να παρέχουν βελτιωμένες ταχύτητες και χαμηλή καθυστέρηση.

1. Φάσματα

- **Χαμηλό Φάσμα:** Παρέχει μεγάλη κάλυψη και καλή διείσδυση μέσα από εμπόδια, αν και με χαμηλότερες ταχύτητες. Η συνεισφορά του χαμηλού φάσματος μπορεί να μετρηθεί με την εξίσωση:

$$\text{Data Rate}_{\text{Low Band}} = \text{Frequency Bandwidth} \times \text{Signal Strength}$$

Ρυθμός Δεδομένων Χαμηλής Ζώνης = Εύρος Ζώνης Συχνότητας $\times$ Ισχύς Σήματος

- **Μεσαίο Φάσμα:** Ισορροπεί την ταχύτητα και την κάλυψη, επιτρέποντας καλές αποδόσεις σε μεγάλες αποστάσεις. (Liu & Zhang, 2021)
- **Υψηλό Φάσμα (mmWave):** Παρέχει υψηλές ταχύτητες και χαμηλή καθυστέρηση, με περιορισμένη εμβέλεια. Η επίδραση των mmWave στην ταχύτητα περιγράφεται με το μοντέλο:

$$\text{Data Rate}_{\text{mmWave}} = \text{Channel Capacity} \cdot \log_2(1 + \text{Signal} - \text{to} - \text{Noise Ratio})$$

$$\text{Ρυθμός Δεδομένων mmWave} = \text{Χωρητικότητα Καναλιού} \cdot \log_2(1 + \text{Λόγος Σήματος προς Θόρυβο})$$

2. Υποδομή Δικτύου

- **Βάσεις Σταθμών:** Υποστηρίζουν την εκπομπή και λήψη σημάτων. Ο αριθμός των βάσεων σταθμών επηρεάζει τη συνολική κάλυψη και ταχύτητα δικτύου. (Yang & Zhou, 2022)

- **Μικρές Κυψέλες :** Ενισχύουν τη χωρητικότητα και είναι σημαντικές για την ανάπτυξη mmWave σε περιοχές υψηλής ζήτησης.
- **Οπτικές Ίνες:** Υποστηρίζουν τη γρήγορη μεταφορά δεδομένων από τις βάσεις σταθμών στο κεντρικό δίκτυο.

3. Κεντρικό Δίκτυο

- **Δίκτυα Ορισμένα από Λογισμικό (SDN):** Αυξάνουν την ευελιξία του δικτύου και επιτρέπουν τη διαχείριση του δικτύου μέσω λογισμικού.
- **Εικονικοποίηση Λειτουργιών Δικτύου (NFV):** Αποσυνδέει τις λειτουργίες του δικτύου από το υλικό, εξασφαλίζοντας κλιμακούμενη κατανομή πόρων. (Xiong & Zhao, 2023)
- **Διαμέριση Δικτύου:** Επιτρέπει πολλαπλά εικονικά δίκτυα για διαφορετικές υπηρεσίες μέσω της εξίσωσης:

$$\text{Network Slice Capacity} = \frac{\text{Total Network Resources}}{\text{Number of Slices}}$$

Χωρητικότητα Τμήματος Δικτύου = Συνολικοί Πόροι Δικτύου / Αριθμός Τμημάτων

4. Ραδιοτεχνολογίες

- **Μαζικό MIMO:** Αυξάνει την χωρητικότητα μέσω πολλαπλών κεραιών, βελτιώνοντας την απόδοση.
- **Διαμόρφωση Δέσμης:** Εστιάζει τα σήματα προς συγκεκριμένους χρήστες για μειωμένες παρεμβολές.

5. Συσκευές

- **Συμβατές Συσκευές με 5G:** Κινητά τηλέφωνα, συσκευές IoT και άλλες συσκευές πρέπει να διαθέτουν μόντεμ 5G.

6. Υπολογισμός στην Άκρη

- **Κέντρα Δεδομένων στην Άκρη:** Προσφέρουν επεξεργασία δεδομένων κοντά στους χρήστες για μειωμένη καθυστέρηση και καλύτερη απόδοση σε εφαρμογές πραγματικού χρόνου.

7. Ασφάλεια

- **Ενισχυμένα Πρωτόκολλα Ασφάλειας:** Προστατεύουν την ακεραιότητα των δεδομένων και την ιδιωτικότητα μέσω κρυπτογράφησης και αυθεντικοποίησης. (Brown, Lee, & Tran, 2022)

8. Ενεργειακή Αποδοτικότητα

- **Διαχείριση Ενέργειας:** Η ενεργειακή αποδοτικότητα υποστηρίζεται από λειτουργίες εξοικονόμησης ενέργειας στις βάσεις σταθμών και συσκευές. (Chen, Yu, & Li, 2021)

9. Πρότυπα και Πρωτόκολλα

- **5G NR (Νέα Ραδιοφωνία):** Το παγκόσμιο πρότυπο για τα δίκτυα 5G.
- **3GPP:** Περιλαμβάνει οργανισμούς που αναπτύσσουν τα πρωτόκολλα για τα ασύρματα δίκτυα.

Διασπώντας το 5G σε αυτά τα απαραίτητα κομμάτια, αποκτάμε μια πιο καθαρή κατανόηση της πολύπλοκης αλλά και έντονα διασυνδεδεμένης δομής του. Κάθε στοιχείο, από την κατανομή του φάσματος μέχρι τις προηγμένες ραδιοτεχνολογίες, παίζει έναν κρίσιμο ρόλο στην παροχή του υψηλής ταχύτητας, χαμηλής καθυστέρησης και υψηλής χωρητικότητας δικτύου που ορίζει το 5G. Αυτό το περίπλοκο δίκτυο τεχνολογιών και υποδομών είναι που επιτρέπει τις επαναστατικές δυνατότητες και εφαρμογές του 5G, ανοίγοντας το δρόμο για ένα πιο συνδεδεμένο και προηγμένο μέλλον.

Παράδειγμα ενός αντιπροσωπευτικού δικτύου 5G στο προγραμματιστικό περιβάλλον του matlab

Αυτό το παράδειγμα κώδικα MATLAB αποτελεί αντιπροσωπευτική υλοποίηση των θεμελιωδών αρχών του φυσικού επιπέδου (physical layer) ενός δικτύου 5G, παρουσιάζοντας βασικά χαρακτηριστικά που συναντώνται στη συγκεκριμένη τεχνολογία.

1. **Συχνότητα Φορέα:** Η επιλογή συχνότητας φορέα στα 28 GHz βρίσκεται στην περιοχή των millimeter waves (mmWave), μια από τις χαρακτηριστικές ζώνες συχνοτήτων του 5G, η οποία επιτρέπει υψηλό ρυθμό δεδομένων και ευρεία χωρητικότητα. Τα συστήματα 5G χρησιμοποιούν mmWave συχνότητες για τη

μεγιστοποίηση της χωρητικότητας, παρέχοντας μεγαλύτερο εύρος ζώνης και υψηλότερες ταχύτητες μετάδοσης δεδομένων σε σχέση με τις προηγούμενες γενιές.

2. **Απόσταση Υποφορέων και Εύρος Ζώνης:** Οι ρυθμίσεις απόστασης υποφορέων (30 kHz) και εύρους ζώνης (100 MHz) συμβαδίζουν με τα πρότυπα του 5G. Το OFDM (Orthogonal Frequency Division Multiplexing) αποτελεί την κύρια τεχνική διαμόρφωσης που υιοθετείται από το 5G για την αντιμετώπιση της παρεμβολής και της πολυδιαδρομικής διάδοσης, εξασφαλίζοντας βέλτιστη αποδοτικότητα του φάσματος και σταθερότητα σήματος.
3. **MIMO (Multiple Input Multiple Output):** Η χρήση πολλαπλών κεραιών είναι κρίσιμη για την υλοποίηση του Massive MIMO, το οποίο ενισχύει την απόδοση των δικτύων 5G. Το Massive MIMO επιτρέπει την ταυτόχρονη μετάδοση και λήψη πολλαπλών σημάτων, βελτιώνοντας την αξιοπιστία και την ταχύτητα μετάδοσης δεδομένων μέσω της αύξησης της χωρητικότητας και της αντοχής στο θόρυβο.
4. **Κανάλι Rayleigh:** Το μοντέλο καναλιού Rayleigh χρησιμοποιείται για την προσομοίωση της διάδοσης του σήματος σε περιβάλλοντα με έντονες ανακλάσεις, όπως σε αστικά περιβάλλοντα, όπου η διάδοση του σήματος επηρεάζεται από πολλαπλές διαδρομές. Αν και το μοντέλο Rayleigh δεν λαμβάνει υπόψη όλες τις συνθήκες ενός πραγματικού καναλιού 5G (όπως το path loss και το shadowing), παρέχει μια θεμελιώδη βάση για την ανάλυση της συμπεριφοράς των σημάτων σε δυναμικά περιβάλλοντα.

% Παράμετροι Συστήματος

fc = 28e9; % Συχνότητα φορέα (28 GHz)

bw = 100e6; % Εύρος ζώνης (100 MHz)

scs = 30e3; % Απόσταση υποφορέων (30 kHz)

nSubcarriers = floor(bw / scs); % Αριθμός υποφορέων (εξασφάλιση ότι είναι ακέραιος)

nAntennas = 64; % Αριθμός κεραιών (MIMO)

% Παράμετροι Χρονικού Πεδίου

```

nSymbols = 14;          % Αριθμός συμβόλων OFDM ανά υποδοχή

samplingRate = nSubcarriers * scs; % Ρυθμός δειγματοληψίας

% Δημιουργία κυματομορφής OFDM

txWaveform = complex(randn(nSubcarriers, nSymbols), randn(nSubcarriers,
nSymbols));

% Εμφάνιση παραμέτρων συστήματος

disp('Οι Παράμετροι του Συστήματος Αρχικοποιήθηκαν');

% Διαμόρφωση OFDM

ofdmMod = comm.OFDMModulator('FFTLength', nSubcarriers,
'NumGuardBandCarriers', [0; 0], ...
'CyclicPrefixLength', 72, 'NumSymbols', nSymbols);

% Διαμόρφωση του σήματος

txOFDM = ofdmMod(txWaveform);

% Εμφάνιση λεπτομερειών διαμόρφωσης

disp('Η Διαμόρφωση OFDM Ολοκληρώθηκε');

% Ορισμός ενός βασικού καναλιού Rayleigh

channel = comm.RayleighChannel('SampleRate', samplingRate, ...
'PathDelays', [0 1.5e-6], 'AveragePathGains', [0 -3]);

% Μετάδοση σήματος μέσω του καναλιού

rxOFDM = channel(txOFDM);

```

```

% Εμφάνιση λεπτομερειών καναλιού
disp('Η Μοντελοποίηση του Καναλιού Ολοκληρώθηκε');

% Αποδιαμόρφωση OFDM
ofdmDemod = comm.OFDMDemodulator('FFTLength', nSubcarriers,
'NumGuardBandCarriers', [0; 0], ...
'CyclicPrefixLength', 72, 'NumSymbols', nSymbols);

% Αποδιαμόρφωση του ληφθέντος σήματος
rxWaveform = ofdmDemod(rxOFDM);

% Εμφάνιση λεπτομερειών αποδιαμόρφωσης
disp('Η Αποδιαμόρφωση OFDM Ολοκληρώθηκε');

% Υπολογισμός ποιότητας του ληφθέντος σήματος
receivedPower = mean(abs(rxWaveform(:)).^2);
disp(['Ισχύς Λήψης: ', num2str(10*log10(receivedPower)), ' dB']);

% Υπολογισμός Σφάλματος
mse = mean(abs(txWaveform(:) - rxWaveform(:)).^2);
snr = 10*log10(mean(abs(txWaveform(:)).^2) / mse);

disp(['Μέσο Τετραγωνικό Σφάλμα: ', num2str(mse)]);
disp(['Λόγος Σήματος προς Θόρυβο: ', num2str(snr), ' dB']);

% Σχεδίαση των διαμορφωμένων και ληφθέντων κυματομορφών

```

```

figure;

subplot(2, 1, 1);

plot(real(txOFDM));

title('Διαμορφωμένο Σήμα OFDM');

xlabel('Δείκτης Δείγματος');

ylabel('Πλάτος');

grid on;


subplot(2, 1, 2);

plot(real(rxOFDM));

title('Ληφθέν Σήμα OFDM');

xlabel('Δείκτης Δείγματος');

ylabel('Πλάτος');

grid on;


% Δημιουργία απόκρισης κρουστικού σήματος του καναλιού

impulse = [1; zeros(1023, 1)]; % Κρουστικό σήμα

channelOutput = channel(impulse);


% Σχεδίαση απόκρισης κρουστικού σήματος του καναλιού

figure;

stem(abs(channelOutput));

title('Απόκριση Κρουστικού Σήματος του Καναλιού');

xlabel('Δείκτης Δείγματος');

ylabel('Πλάτος');

grid on;

```

```
% Σχεδίαση ληφθέντων συμβόλων μετά την αποδιαμόρφωση OFDM
```

```
figure;
```

```
subplot(2, 1, 1);
```

```
plot(real(txWaveform(:)));
```

```
title('Διαμορφωμένα Σύμβολα OFDM');
```

```
xlabel('Δείκτης Συμβόλου');
```

```
ylabel('Πλάτος');
```

```
grid on;
```

```
subplot(2, 1, 2);
```

```
plot(real(rxWaveform(:)));
```

```
title('Ληφθέντα Σύμβολα OFDM');
```

```
xlabel('Δείκτης Συμβόλου');
```

```
ylabel('Πλάτος');
```

```
grid on;
```

Επεξήγηση του κώδικα

Ο κώδικας που παρέχετε υλοποιεί τη διαδικασία διαμόρφωσης και αποδιαμόρφωσης OFDM (Orthogonal Frequency Division Multiplexing) σε ένα περιβάλλον MIMO (Multiple Input Multiple Output) με τη χρήση καναλιού Rayleigh. Ακολουθεί μια ανάλυση των κύριων τμημάτων του κώδικα και των αποτελεσμάτων που προκύπτουν από τη διαδικασία.

1. Ρυθμίσεις Συστήματος

1.1 Παράμετροι Συστήματος

```
matlab
```

```
fc = 28e9;          % Συχνότητα φορέα (28 GHz)
```

```

bw = 100e6;          % Εύρος ζώνης (100 MHz)
scs = 30e3;          % Απόσταση υποφορέων (30 kHz)
nSubcarriers = floor(bw / scs); % Αριθμός υποφορέων (εξασφάλιση ότι είναι ακέραιος)
nAntennas = 64;      % Αριθμός κεραιών (MIMO)

```

Οι παράμετροι συστήματος ορίζονται στην αρχή του κώδικα. Η συχνότητα φορέα καθορίζεται σε 28 GHz, η οποία είναι χαρακτηριστική για τις σύγχρονες ασύρματες επικοινωνίες, όπως το 5G. Το εύρος ζώνης 100 MHz και η απόσταση υποφορέων 30 kHz επιτρέπουν τη δημιουργία 3333 υποφορέων, παρέχοντας επαρκή χωρητικότητα για τη διανομή δεδομένων.

2. Δημιουργία Κυματομορφής OFDM

2.1 Δημιουργία Σημάτων

matlab

```

txWaveform = complex(randn(nSubcarriers, nSymbols), randn(nSubcarriers, nSymbols));

```

Η κυματομορφή μετάδοσης δημιουργείται χρησιμοποιώντας τυχαία σύμβολα, αναπαριστώμενα ως σύνθετοι αριθμοί. Αυτή η προσέγγιση επιτρέπει την προσομοίωση μιας πραγματικής διαδικασίας διαμόρφωσης, όπου τα σύμβολα διαμορφώνονται σε ένα πλέγμα διαστάσεων $n_{\text{Subcarriers}} \times n_{\text{Symbols}}$ $\times$ $n_{\text{Subcarriers}}$ $\times$ n_{Symbols} .

2.2 Διαμόρφωση OFDM

matlab

```

ofdmMod = comm.OFDMModulator('FFTLength', nSubcarriers,
'NumGuardBandCarriers', [0; 0], ...
'CyclicPrefixLength', 72, 'NumSymbols', nSymbols);
txOFDM = ofdmMod(txWaveform);

```

Ο διαμορφωτής OFDM χρησιμοποιεί τη μετασχηματισμένη Fast Fourier Transform (FFT) για να παράγει την OFDM κυματομορφή από τα τυχαία σύμβολα. Η προσθήκη κυκλικού προθέματος (cyclic prefix) βοηθά στην αποφυγή παρεμβολών και στην προστασία της κυματομορφής από ανακλάσεις.

3. Μοντελοποίηση Καναλιού

3.1 Ορισμός Καναλιού Rayleigh

matlab

```
channel = comm.RayleighChannel('SampleRate', samplingRate, ...  
    'PathDelays', [0 1.5e-6], 'AveragePathGains', [0 -3]);
```

Η μοντελοποίηση του καναλιού Rayleigh αναπαριστά την ασύρματη μετάδοση σε περιβάλλοντα με πολλαπλές διαδρομές (multipath). Ορίζονται καθυστερήσεις διαδρομών και μέσες απώλειες, με αποτέλεσμα να προσομοιώνονται οι συνθήκες πραγματικού κόσμου, όπου τα σήματα φθάνουν στον δέκτη μέσω διαφορετικών διαδρομών.

3.2 Μετάδοση Σήματος

matlab

```
rxOFDM = channel(txOFDM);
```

Το διαμορφωμένο σήμα OFDM μεταδίδεται μέσω του καναλιού Rayleigh, επιτρέποντας την αξιολόγηση της ποιότητας του σήματος μετά τη μετάδοση.

4. Αποδιαμόρφωση OFDM

4.1 Αποδιαμόρφωση

matlab

```
ofdmDemod = comm.OFDMDemodulator('FFTLength', nSubcarriers,  
    'NumGuardBandCarriers', [0; 0], ...  
    'CyclicPrefixLength', 72, 'NumSymbols', nSymbols);
```

```
rxWaveform = ofdmDemod(rxOFDM);
```

Αυτή η διαδικασία αποδιαμόρφωσης ανακτά το αρχικό σήμα OFDM από το ληφθέν σήμα, επιτρέποντας την εκτίμηση της ποιότητας του σήματος.

5. Αξιολόγηση Απόδοσης

5.1 Υπολογισμός Ικανότητας Σήματος

matlab

```
receivedPower = mean(abs(rxWaveform(:)).^2);  
disp(['Ισχύς Λήψης: ', num2str(10*log10(receivedPower)), ' dB']);
```

Η ισχύς του ληφθέντος σήματος υπολογίζεται ως ο μέσος όρος του τετραγώνου των ληφθέντων τιμών, και μετατρέπεται σε dB για ευκολότερη ερμηνεία.

5.2 Υπολογισμός Σφάλματος

matlab

```
mse = mean(abs(txWaveform(:) - rxWaveform(:)).^2);  
snr = 10*log10(mean(abs(txWaveform(:)).^2) / mse);  
disp(['Μέσο Τετραγωνικό Σφάλμα: ', num2str(mse)]);  
disp(['Λόγος Σήματος προς Θόρυβο: ', num2str(snr), ' dB']);
```

Το μέσο τετραγωνικό σφάλμα (MSE) υπολογίζεται για την εκτίμηση της ποιότητας του σήματος. Ο λόγος σήματος προς θόρυβο (SNR) υπολογίζεται επίσης, προσδιορίζοντας την ποιότητα της μετάδοσης. Υψηλές τιμές SNR υποδηλώνουν καλή ποιότητα σήματος.

6. Οπτικοποίηση Αποτελεσμάτων

6.1 Σχεδίαση Κυματομορφών

matlab

```
figure;  
subplot(2, 1, 1);  
plot(real(txOFDM));  
title('Διαμορφωμένο Σήμα OFDM');  
xlabel('Δείκτης Δείγματος');  
ylabel('Πλάτος');  
grid on;
```

```
subplot(2, 1, 2);  
plot(real(rxOFDM));  
title('Ληφθέν Σήμα OFDM');  
xlabel('Δείκτης Δείγματος');  
ylabel('Πλάτος');  
grid on;
```

Οι κυματομορφές του διαμορφωμένου και του ληφθέντος σήματος απεικονίζονται, διευκολύνοντας την οπτική αξιολόγηση της διαδικασίας μετάδοσης και των επιδράσεων του καναλιού.

6.2 Απόκριση Κρουστικού Σήματος

matlab

```
impulse = [1; zeros(1023, 1)]; % Κρουστικό σήμα
channelOutput = channel(impulse);
```

```
figure;
stem(abs(channelOutput));
title('Απόκριση Κρουστικού Σήματος του Καναλιού');
xlabel('Δείκτης Δείγματος');
ylabel('Πλάτος');
grid on;
```

Η απόκριση κρουστικού σήματος του καναλιού σχεδιάζεται, παρέχοντας πληροφορίες για την απόκριση του καναλιού σε συγκεκριμένες εισροές.

6.3 Σύμβολα

```
matlab
figure;
subplot(2, 1, 1);
plot(real(txWaveform(:)));
title('Διαμορφωμένα Σύμβολα OFDM');
xlabel('Δείκτης Συμβόλου');
ylabel('Πλάτος');
grid on;
```

```
subplot(2, 1, 2);
plot(real(rxWaveform(:)));
title('Ληφθέντα Σύμβολα OFDM');
xlabel('Δείκτης Συμβόλου');
ylabel('Πλάτος');
grid on;
```

Αυτή η απεικόνιση επιτρέπει την παρακολούθηση της ποιότητας των συμβόλων πριν και μετά τη μετάδοση, επισημαίνοντας τις διαφορές που προκύπτουν από την ασύρματη μετάδοση.

Αποτελέσματα Προσομείωσης

Οι Παράμετροι του Συστήματος Αρχικοποιήθηκαν
Η Διαμόρφωση OFDM Ολοκληρώθηκε
Η Μοντελοποίηση του Καναλιού Ολοκληρώθηκε
Η Αποδιαμόρφωση OFDM Ολοκληρώθηκε
Ισχύς Λήψης: -0.33756 dB
Μέσο Τετραγωνικό Σφάλμα: 3.2583 (MSE)
Λόγος Σήματος προς Θόρυβο: -2.1328 dB (SNR)

Συμπεράσματα

Επίδοση Συστήματος: Οι υπολογισμοί SNR και MSE παρέχουν σημαντικές πληροφορίες σχετικά με την απόδοση του συστήματος. Ένα υψηλό SNR υποδηλώνει ότι το σύστημα λειτουργεί αποτελεσματικά, ενώ ένα χαμηλό MSE υποδεικνύει ότι οι διαμορφωμένες και οι ληφθείσες κυματομορφές είναι κοντά μεταξύ τους.

Δυνατότητες MIMO: Με τη χρήση 64 κεραιών, το σύστημα μπορεί να επωφεληθεί από τις δυνατότητες του MIMO, επιτρέποντας μεγαλύτερες ταχύτητες μετάδοσης και βελτιωμένη αξιοπιστία σε ασύρματα δίκτυα.

Αυτή η ανάλυση υπογραμμίζει τη σημασία της χρήσης αλγορίθμων OFDM σε σύγχρονες επικοινωνίες και τονίζει τις επιπτώσεις της ασύρματης μετάδοσης μέσω καναλιών Rayleigh, συμβάλλοντας στη συνολική κατανόηση της λειτουργίας και των επιδόσεων των συστημάτων επικοινωνίας.

Αποτελέσματα κώδικα-Διαγράμματα




Figure 13 Αποτέλεσμα matlab

Διάγραμμα Διαμορφωμένου και Ληφθέντος Σήματος OFDM

Διαμορφωμένο Σήμα OFDM

Στο πρώτο υποδιάγραμμα, βλέπουμε το **διαμορφωμένο σήμα OFDM**. Αυτό το διάγραμμα απεικονίζει την κυματομορφή που δημιουργήθηκε μετά την εφαρμογή της διαμόρφωσης OFDM στη μονάδα εκπομπής και πριν περάσει από το κανάλι.

- **Άξονας X:** Οριζόντιος άξονας που αντιπροσωπεύει το δείκτη δείγματος, δηλαδή τον αριθμό του δείγματος που δημιουργείται στον χρόνο.
- **Άξονας Y:** Κατακόρυφος άξονας που αντιπροσωπεύει το πλάτος του σήματος, δηλαδή την ένταση του σήματος ανά δείγμα.

Το σήμα OFDM αποτελείται από πολλά υπο-σήματα που μεταδίδονται ταυτόχρονα και συγχρονισμένα, γι' αυτό παρατηρούμε ένα πολύπλοκο κυματομορφικό μοτίβο.

Ληφθέν Σήμα OFDM

Στο δεύτερο υποδιάγραμμα, βλέπουμε το **ληφθέν σήμα OFDM** αφού έχει περάσει από το κανάλι Rayleigh.

- Στο κανάλι Rayleigh έχει προστεθεί πολυδιάδρομο fading, το οποίο δημιουργεί διαφορές στην ένταση και τη φάση του σήματος λόγω των πολλαπλών οδών διάδοσης.
- Οι επιδράσεις του καναλιού είναι εμφανείς στις αλλοιώσεις της κυματομορφής, όπου το ληφθέν σήμα μπορεί να έχει υποστεί εξασθένιση και παραμόρφωση σε σχέση με το διαμορφωμένο σήμα.

Αυτό το διάγραμμα επιτρέπει τη σύγκριση του διαμορφωμένου και του ληφθέντος σήματος, ώστε να διαπιστώσουμε πώς επηρεάστηκε το σήμα από το κανάλι.




Figure 14 Αποτέλεσμα matlab

Απόκριση Κρουστικού Σήματος του Καναλιού

Το διάγραμμα αυτό απεικονίζει την **απόκριση του καναλιού σε κρουστικό σήμα**, το οποίο προσομοιώνεται με έναν παλμό ενέργειας στο χρονικό πεδίο.

- **Άξονας X:** Δείκτης δείγματος, ο οποίος αντιπροσωπεύει τον χρόνο σε διακριτά βήματα.
- **Άξονας Y:** Το πλάτος της απόκρισης σε κάθε δείγμα.

Αυτό το διάγραμμα δείχνει πώς ανταποκρίνεται το κανάλι σε έναν μόνο παλμό, δηλαδή τον τρόπο με τον οποίο το σήμα διαχέεται και μειώνεται η έντασή του καθώς επηρεάζεται από τις πολλαπλές οδούς διάδοσης και τη δυναμική της εκάστοτε καθυστέρησης. Στη συγκεκριμένη περίπτωση, το κανάλι Rayleigh προκαλεί εξασθένιση και καθυστερήσεις στις πολλαπλές οδούς του σήματος.




Figure 15 Αποτέλεσμα matlab

Διαμορφωμένα και Ληφθέντα Σύμβολα OFDM

Διαμορφωμένα Σύμβολα OFDM

Στο πρώτο υποδιάγραμμα, βλέπουμε τα **διαμορφωμένα σύμβολα OFDM**. Κάθε σύμβολο αντιστοιχεί σε ένα σύνολο από πληροφορίες που διαμορφώνονται και μεταφέρονται σε διαφορετικές συχνότητες.

- **Άξονας X:** Δείκτης συμβόλου, δηλαδή η χρονική σειρά των διαδοχικών συμβόλων που εκπέμπονται.
- **Άξονας Y:** Το πλάτος του κάθε συμβόλου, το οποίο υποδεικνύει την ένταση ή το μέγεθος του συμβόλου στον άξονα του πραγματικού μέρους.

Ληφθέντα Σύμβολα OFDM

Το δεύτερο υποδιάγραμμα δείχνει τα **ληφθέντα σύμβολα OFDM** μετά την αποδιαμόρφωση.

- Τα ληφθέντα σύμβολα έχουν πιθανότητα επηρεαστεί από το κανάλι, γεγονός που μπορεί να προκαλέσει παραμορφώσεις λόγω του θορύβου και της εξασθένισης που έχει υποστεί το σήμα.

- Αν τα ληφθέντα σύμβολα είναι αρκετά αλλοιωμένα, θα μπορούσαμε να δούμε διαφορές στο πλάτος και τη θέση των συμβόλων σε σχέση με τα διαμορφωμένα.

Αυτά τα διαγράμματα, σε συνδυασμό με τους υπολογισμούς ποιότητας (ισχύς λήψης, SNR, MSE), παρέχουν πολύτιμη πληροφορία για την απόδοση του καναλιού και την ποιότητα της μετάδοσης στο δίκτυο. Το μέσο τετραγωνικό σφάλμα (MSE) και ο λόγος σήματος προς θόρυβο (SNR) βοηθούν στην ποσοτική εκτίμηση των διαφορών μεταξύ του αρχικού και του ληφθέντος σήματος.

Η Εφαρμογή της Q-learning στα Δίκτυα 5G

Η Q-learning, ως αλγόριθμος μάθησης ενίσχυσης, χρησιμοποιείται στα δίκτυα 5G για τη βελτιστοποίηση της διαχείρισης και της αποδοτικότητας του δικτύου σε πραγματικό χρόνο.

1. Κατανομή Πόρων

- **Διαχείριση Φάσματος Δυναμικά:** Η Q-learning βοηθά στην κατανομή του φάσματος με βάση τη ζήτηση και τις συνθήκες του δικτύου, εξασφαλίζοντας τη βέλτιστη χρήση πόρων και τη μείωση των παρεμβολών. (Zhao & Lin, 2022)
- **Κατανομή Ζώνης Ζεύξης:** Η Q-learning βελτιστοποιεί τη δυναμική κατανομή της ζώνης ζεύξης για χρήστες και υπηρεσίες, μεγιστοποιώντας την αποδοτικότητα σε συνθήκες μεταβαλλόμενου φορτίου.

2. Διαμερισμός Δικτύου

- **Αποδοτική Διαχείριση Διαμερισμάτων:** Η Q-learning προσαρμόζει την κατανομή πόρων στα διαμερίσματα δικτύου, ώστε κάθε εικονικό δίκτυο να ανταποκρίνεται στις απαιτήσεις απόδοσης.

3. Ενεργειακή Αποδοτικότητα

- **Διαχείριση Ισχύος:** Η Q-learning βελτιστοποιεί την κατανάλωση ισχύος σε βάσεις σταθμών και συσκευές, επιλέγοντας ρυθμίσεις που εξισορροπούν την απόδοση και την ενέργεια. (Chen & Liu, 2023)
- **Βελτιστοποίηση Λειτουργιών Ύπνου:** Μέσω της πρόβλεψης πρότυπων κίνησης, η Q-learning ενεργοποιεί ή απενεργοποιεί μικρό κυψέλες μόνο όταν είναι απαραίτητο.

4. Διαχείριση Κίνησης

- **Ισοστάθμιση Φορτίου:** Η Q-learning διανέμει το φορτίο του δικτύου σε λιγότερο φορτωμένες διαδρομές, βελτιώνοντας την εμπειρία χρήστη και αποφεύγοντας τη συμφόρηση. (Wu, Liu, & Chen, 2021)
- **Έλεγχος Συμφόρησης:** Προβλέπει και προλαμβάνει τη συμφόρηση με ανακατεύθυνση της κίνησης και προσαρμογή των παραμέτρων μετάδοσης.

5. Διαχείριση Παρεμβολών

- **Προσαρμοστική Δέσμη Προσέγγισης:** Σε Massive MIMO, η Q-learning βελτιστοποιεί τις διαμορφώσεις δέσμης για μείωση των παρεμβολών και ενίσχυση της ποιότητας σήματος.
- **Συντονισμός Παρεμβολών Μεταξύ Κυψελών:** Η Q-learning συντονίζει τις επικαλυπτόμενες κυψέλες, μειώνοντας τις παρεμβολές σε πυκνοκατοικημένες περιοχές. (Gao, Zhang, & Zhao, 2022)

6. Εξασφάλιση Ποιότητας Υπηρεσίας (QoS)

- **Διαφοροποίηση Υπηρεσιών:** Η Q-learning διαχειρίζεται τις παραμέτρους δικτύου ώστε διαφορετικές υπηρεσίες (όπως ροή βίντεο και IoT) να λαμβάνουν την κατάλληλη ποιότητα.
- **Βελτιστοποίηση Καθυστέρησης:** Προσαρμόζει τη δρομολόγηση και τους πόρους για να μειώσει την καθυστέρηση σε εφαρμογές που είναι ευαίσθητες στον χρόνο. (Lee & Park, 2022)

7. Βελτίωση Εμπειρίας Χρήστη

- **Προσωποποιημένες Υπηρεσίες:** Αναλύει τις προτιμήσεις χρήστη για να προσφέρει εξατομικευμένες υπηρεσίες, όπως προσαρμοσμένη κατανομή εύρους ζώνης.
- **Απρόσκοπτη Μεταφορά:** Βελτιστοποιεί τη μεταφορά μεταξύ κυψελών, διασφαλίζοντας απρόσκοπτη εμπειρία για χρήστες σε κίνηση. (Huang & Yang, 2023)

Η ενισχυτική μάθηση, με κεντρικό αλγόριθμο τον Q-learning, έχει αναδειχθεί ως ένα ισχυρό εργαλείο για την βελτιστοποίηση της απόδοσης των δικτύων 5G. Η δυνατότητα της Q-learning να μαθαίνει από τις αλληλεπιδράσεις της με το περιβάλλον, επιτρέπει την ανάπτυξη δυναμικών στρατηγικών διαχείρισης πόρων, βελτιστοποιώντας παράμετρους όπως η κατανομή ισχύος, η διαμόρφωση κώδικα και η επιλογή συχνότητας. Επιπλέον, η Q-learning συμβάλλει στην επίτευξη ενεργειακής αποδοτικότητας, στη μείωση των καθυστερήσεων και στην εξασφάλιση της ποιότητας των υπηρεσιών, αντιμετωπίζοντας έτσι τις αυξανόμενες απαιτήσεις των εφαρμογών του Διαδικτύου των Πραγμάτων (IoT) και των υπηρεσιών χαμηλής καθυστέρησης υψηλής αξιοπιστίας (URLLC). Η ενσωμάτωση της Q-learning στα δίκτυα 5G αποτελεί ένα σημαντικό βήμα προς την υλοποίηση των οραμάτων των δικτύων πέμπτης γενιάς, όπως η αυτοματοποίηση, η ευφυΐα και η προσαρμοστικότητα.

Στόχος είναι να βελτιστοποιήσουμε τη διαχείριση ενός δικτύου 5G χρησιμοποιώντας ενισχυτική μάθηση. Σκοπός είναι να βελτιώσουμε τη συνολική απόδοση του δικτύου όσον αφορά τον ρυθμό μετάδοσης, την καθυστέρηση και τη χρήση πόρων, κατανέμοντας δυναμικά πόρους και λαμβάνοντας αυτόνομες αποφάσεις για μετάδοση και έλεγχο ισχύος.

Συστατικά Μοντέλου Ενισχυτικής Μάθησης σε ένα περιβάλλον δικτύου 5G με χρήση Μαρκοβιανών Διαδικασιών Απόφασης (MDP)

1. **Καταστάσεις (S):** Η κατάσταση του δικτύου τη στιγμή t μπορεί να οριστεί ως ένα σύνολο που αναπαριστά διάφορες συνθήκες του δικτύου:

$$S_t = \{s_1, s_2, \dots, s_n\}$$

όπου s_i περιλαμβάνει:

- ο Την τοποθεσία των UEs
- ο Την ισχύ του σήματος
- ο Το φορτίο στις βάσεις σταθμών
- ο Τα επίπεδα παρεμβολών
- ο Τους τρέχοντες κατανεμημένους πόρους

2. **Δράσεις (A):** Οι δράσεις που αναλαμβάνει ο πράκτορας (ελεγκτής δικτύου) περιλαμβάνουν:

$$A_t = \{a_1, a_2, \dots, a_m\}$$

όπου αι αναπαριστά:

- ο Κατανομή εύρους ζώνης
- ο Ρυθμίσεις ελέγχου ισχύος
- ο Επιλογή βάσεων σταθμών για μετάδοση
- ο Δυναμική κατανομή φάσματος

3. **Ανταμοιβές (R):** Η συνάρτηση ανταμοιβής R_t αντικατοπτρίζει την απόδοση του δικτύου και μπορεί να οριστεί ως:

$$R_t = \alpha \times \text{διακίνηση δεδομένων} + \beta \times \text{καθυστέρηση} + \gamma \times \text{χρήση πόρων}$$

όπου α , β , και γ είναι βάρη που ισορροπούν τη σημασία κάθε μετρικής.

4. **Πιθανότητες Μετάβασης ($P(s'|s,a)$):** Η πιθανότητα μετάβασης σε μια νέα κατάσταση s' δεδομένης της τρέχουσας κατάστασης s και της δράσης a .

Πλαίσιο Ενισχυτικής Μάθησης

Μοντελοποιούμε το πρόβλημα ως μια Διαδικασία Μαρκοβιανής Απόφασης (MDP):

1. **Συνάρτηση Αξίας Κατάστασης $V(s)$:**

$$V^\pi(s) = E_\pi[\sum_{t=0}^{\infty} \gamma^t R_{t+1} | S_t = s]$$

όπου γ είναι ο παράγοντας προεξόφλησης.

2. **Συνάρτηση Αξίας Δράσης $Q(s,a)$:**

$$Q^\pi(s,a) = E_\pi[\sum_{t=0}^{\infty} \gamma^t R_{t+1} | S_t = s, A_t = a]$$

3. **Πολιτική $\pi(a|s)$:** Η πολιτική καθορίζει τη δράση που λαμβάνεται σε κάθε κατάσταση για να μεγιστοποιηθεί η αναμενόμενη ανταμοιβή.

Εφαρμογή Ενισχυτικής Μάθησης

Αλγόριθμος Q-Learning

1. **Αρχικοποίηση:** Αρχικοποιούμε τις τιμές Q αυθαίρετα (π.χ., $Q(s,a)=0$) για όλα τα ζεύγη κατάστασης-δράσης.
2. **Βρόχος Επεισοδίου:** Για κάθε επεισόδιο:
 - ο Αρχικοποιούμε την κατάσταση s .
 - ο Επαναλαμβάνουμε για κάθε βήμα του επεισοδίου μέχρι να επιτευχθεί η τελική κατάσταση:

Επιλογή Δράσης: Επιλέγουμε μια δράση a με βάση την τρέχουσα κατάσταση s χρησιμοποιώντας μια πολιτική ϵ -greedy.

Εκτέλεση Δράσης: Εκτελούμε τη δράση a και παρατηρούμε την ανταμοιβή r και την επόμενη κατάσταση s' .

Ενημέρωση Τιμής Q: Ενημερώνουμε την τιμή Q χρησιμοποιώντας τον κανόνα ενημέρωσης του Q-learning:
$$Q(s,a) \leftarrow Q(s,a) + \alpha [r + \gamma \max_{a'} Q(s',a') - Q(s,a)]$$

Μετάβαση Κατάστασης: Μεταβαίνουμε στην επόμενη κατάσταση s' .

- Τέλος του βρόχου βήματος.

3. **Ενημέρωση Πολιτικής:** Παράγουμε την πολιτική π από τις τιμές Q επιλέγοντας τη δράση με την υψηλότερη τιμή Q σε κάθε κατάσταση:

$$\pi(s) = \arg \max_a Q(s,a)$$

Παράδειγμα Εφαρμογής

Δυναμική Κατανομή Φάσματος

Ας θεωρήσουμε ένα απλοποιημένο σενάριο όπου εφαρμόζουμε RL για τη δυναμική κατανομή φάσματος:

1. **Καταστάσεις (S):** Αναπαριστούν την τρέχουσα χρήση φάσματος και το φορτίο στις βάσεις σταθμών.
2. **Δράσεις (A):** Κατανομή διαφορετικών τμημάτων του φάσματος σε διαφορετικούς UEs.
3. **Ανταμοιβές (R):** Ορίζονται με βάση τον ρυθμό μετάδοσης και τα επίπεδα παρεμβολών:

$$R_t = \text{ρυθμός μετάδοσης} - \text{παρεμβολές}$$

Εφαρμογή σε Q-Learning

1. Αρχικοποιούμε $Q(s,a)$.
2. Για κάθε χρονική στιγμή:
 - Παρατηρούμε την τρέχουσα κατάσταση s .
 - Επιλέγουμε μια δράση a (κατανομή φάσματος) χρησιμοποιώντας την πολιτική ϵ -greedy.
 - Εκτελούμε τη δράση και παρατηρούμε την ανταμοιβή r και τη νέα κατάσταση s' .

- ο Ενημερώνουμε την τιμή Q:

$$Q(s,a) \leftarrow Q(s,a) + \alpha [r + \gamma \max_{a'} Q(s',a') - Q(s,a)]$$
- ο Μεταβαίνουμε στην επόμενη κατάσταση s'.

Μέσω της επανάληψης αυτής της διαδικασίας, ο πράκτορας της RL μαθαίνει μια βέλτιστη πολιτική για τη δυναμική κατανομή φάσματος στο δίκτυο 5G, βελτιώνοντας τον ρυθμό μετάδοσης και μειώνοντας τις παρεμβολές με την πάροδο του χρόνου.

Εφαρμογές της τεχνικής Q-Learning σε δίκτυα 5G με την βοήθεια του matlab

Εδώ θα δώσουμε ένα παράδειγμα εφαρμογής ενός q-learning αλγορίθμου σε ένα δίκτυο 5G στο προγραμματιστικό περιβάλλον του matlab. Το παράδειγμα αυτό αποτελεί επέκταση του προηγούμενου ενσωματώνοντας τεχνικές Q-learning .

Παράδειγμα 1 εφαρμογής q-learning αλγορίθμου σε ένα δίκτυο 5G

```
% Παράμετροι Συστήματος

fc = 28e9;           % Συχνότητα φορέα (28 GHz)

bw = 100e6;          % Εύρος ζώνης (100 MHz)

scs = 30e3;          % Απόσταση μεταξύ υποφορέων (30 kHz)

nSubcarriers = floor(bw / scs); % Αριθμός υποφορέων (βεβαιωθείτε ότι είναι ακέραιος)

nAntennas = 64;       % Αριθμός κεραιών (MIMO)

nSymbols = 14;        % Αριθμός συμβόλων OFDM ανά πλαίσιο

samplingRate = nSubcarriers * scs; % Ρυθμός δειγματοληψίας

% Δημιουργία κυματομορφής OFDM
```

```
txWaveform = complex(randn(nSubcarriers, nSymbols), randn(nSubcarriers, nSymbols));
```

```
% Διαμόρφωση OFDM
```

```
ofdmMod = comm.OFDMModulator('FFTLength', nSubcarriers, 'NumGuardBandCarriers', [0; 0], ...
```

```
'CyclicPrefixLength', 72, 'NumSymbols', nSymbols);
```

```
txOFDM = ofdmMod(txWaveform);
```

```
% Ορισμός βασικού καναλιού εξασθένησης Rayleigh
```

```
channel = comm.RayleighChannel('SampleRate', samplingRate, ...
```

```
'PathDelays', [0 1.5e-6], 'AveragePathGains', [0 -3]);
```

```
% Αποδιαμόρφωση OFDM
```

```
ofdmDemod = comm.OFDMDemodulator('FFTLength', nSubcarriers, 'NumGuardBandCarriers', [0; 0], ...
```

```
'CyclicPrefixLength', 72, 'NumSymbols', nSymbols);
```

```
rxOFDM = channel(txOFDM);
```

```
rxWaveform = ofdmDemod(rxOFDM);
```

```
% Υπολογισμός ποιότητας λαμβανόμενου σήματος
```

```
receivedPower = mean(abs(rxWaveform(:)).^2);
```

```
mse = mean(abs(txWaveform(:) - rxWaveform(:)).^2);
```

```
snr = 10 * log10(mean(abs(txWaveform(:)).^2) / mse);
```

```
% Εμφάνιση λεπτομερειών συστήματος και διαμόρφωσης
```

```
disp('Οι Παράμετροι Συστήματος Έχουν Αρχικοποιηθεί');
```

```

disp('Η Διαμόρφωση OFDM Ολοκληρώθηκε');
disp('Το Μοντέλο Καναλιού Ολοκληρώθηκε');
disp('Η Αποδιαμόρφωση OFDM Ολοκληρώθηκε');
disp(['Ισχύς Λαμβανόμενου Σήματος: ', num2str(10*log10(receivedPower)), ' dB']);
disp(['Μέσο Τετραγωνικό Σφάλμα: ', num2str(mse)]);
disp(['Σχέση Σήματος προς Θόρυβο: ', num2str(snr), ' dB']);

```

```

% Σχεδίαση των κυματομορφών που εκπέμπονται και λαμβάνονται

```

```

figure;
subplot(2, 1, 1);
plot(real(txOFDM));
title('Εκπεμπόμενο Σήμα OFDM');
xlabel('Δείκτης Δείγματος');
ylabel('Πλάτος');
grid on;

```

```

subplot(2, 1, 2);
plot(real(rxOFDM));
title('Λαμβανόμενο Σήμα OFDM');
xlabel('Δείκτης Δείγματος');
ylabel('Πλάτος');
grid on;

```

```

% Δημιουργία απόκρισης παλμού του καναλιού
impulse = [1; zeros(1023, 1)]; % Σήμα παλμού
channelOutput = channel(impulse);

```

```
% Σχεδίαση απόκρισης παλμού του καναλιού
```

```
figure;
```

```
stem(abs(channelOutput));
```

```
title('Απόκριση Παλμού Καναλιού');
```

```
xlabel('Δείκτης Δείγματος');
```

```
ylabel('Πλάτος');
```

```
grid on;
```

```
% Σχεδίαση της κυματομορφής μετά την αποδιαμόρφωση OFDM
```

```
figure;
```

```
subplot(2, 1, 1);
```

```
plot(real(txWaveform(:)));
```

```
title('Εκπεμπόμενα Σύμβολα OFDM');
```

```
xlabel('Δείκτης Σύμβολου');
```

```
ylabel('Πλάτος');
```

```
grid on;
```

```
subplot(2, 1, 2);
```

```
plot(real(rxWaveform(:)));
```

```
title('Λαμβανόμενα Σύμβολα OFDM');
```

```
xlabel('Δείκτης Σύμβολου');
```

```
ylabel('Πλάτος');
```

```
grid on;
```

```
% Αρχικοποίηση αρχικής κυματομορφής (για αναφορά)
```



```

originalTxWaveform = txWaveform;

% Ορισμός μέγιστων τιμών για κανονικοποίηση
%maxReceivedPower = 1; % Παράδειγμα τιμής σε dB
%maxSNR = 10;          % Παράδειγμα τιμής σε dB
% Υπολογισμός παρατηρούμενων μέγιστων τιμών για κανονικοποίηση
observedMaxReceivedPower      =      max(mean(abs(rxWaveform(:)).^2),
maxReceivedPower); % Ενημέρωση μέγιστης λαμβανόμενης ισχύος
observedMaxSNR = max(snr, maxSNR); % Ενημέρωση μέγιστου SNR

% Παράμετροι Q-learning
numStates = nSubcarriers; % Για απλότητα, χρησιμοποιήστε τον αριθμό των
υποφορέων ως καταστάσεις
numActions = 10;          % Παράδειγμα αριθμού ενεργειών (π.χ., επίπεδα ισχύος ή
επιλογές υποφορέων)
alpha_values = [0.01, 0.05, 0.1];
gamma_values = [0.5, 0.8, 0.9];
epsilon_values = [0.1, 0.2, 0.3];
maxEpisodes = 10000; % Αριθμός επεισοδίων

best_params = [];
best_reward = -Inf;

for alpha = [0.01, 0.05, 0.1]
    for gamma = [0.5, 0.8, 0.9]
        for epsilon = [0.1, 0.2, 0.3]
            % Εκπαίδευση του πράκτορα Q-learning με τις τρέχουσες υπερπαραμέτρους

```

```

% Αξιολόγηση της απόδοσης του πράκτορα

% Αρχικοποίηση πίνακα Q

Q = zeros(numStates, numActions);

% Εκλεπτυσμένη συνάρτηση ανταμοιβής

rewardFunction = @(receivedPower, mse, snr) (10 * log10(receivedPower) /
maxReceivedPower) + (snr / maxSNR) - mse;

% Αλγόριθμος Q-learning

for episode = 1:maxEpisodes

    state = randi(numStates); % Τυχαία αρχική κατάσταση

    for t = 1:nSymbols

        % Επιλογή ενέργειας χρησιμοποιώντας πολιτική epsilon-greedy

        if rand < epsilon

            action = randi(numActions); % Εξερεύνηση: τυχαία ενέργεια

        else

            [~, action] = max(Q(state, :)); % Εκμετάλλευση: καλύτερη γνωστή
ενέργεια

        end

        % Προσομοίωση της ενέργειας (π.χ., ρύθμιση επιπέδου ισχύος ή επιλογή
υποφορέα)

        txWaveform = originalTxWaveform * (0.8 + 0.04 * action);

        txOFDM = ofdmMod(txWaveform);

        rxOFDM = channel(txOFDM);

        rxWaveform = ofdmDemod(rxOFDM);

```

```

% Υπολογισμός της ποιότητας του λαμβανόμενου σήματος
receivedPower = mean(abs(rxWaveform(:)).^2);

mse = mean(abs(originalTxWaveform(:) - rxWaveform(:)).^2);

snr = 10 * log10(mean(abs(originalTxWaveform(:)).^2) / mse);

% Υπολογισμός της ανταμοιβής
reward = rewardFunction(receivedPower, mse, snr);

% Εύρεση επόμενης κατάστασης (απλουστευμένη ως τυχαία για αυτό το
παράδειγμα)
nextState = randi(numStates);

% Ενημέρωση Q-learning
bestNextAction = max(Q(nextState, :));

Q(state, action) = Q(state, action) + alpha * (reward + gamma *
bestNextAction - Q(state, action));

% Ενημέρωση κατάστασης
state = nextState;

end

end

% Εμφάνιση του πίνακα Q που μάθαμε
disp('Ο Πίνακας Q που Μάθαμε:');

% disp(Q);

```

% Χρησιμοποιήστε τον πίνακα Q που μάθαμε για να προσομοιώσετε την απόδοση του δικτύου 5G

```
state = randi(numStates);
```

```
[~, optimalAction] = max(Q(state, :));
```

% Εφαρμογή της βέλτιστης ενέργειας

```
txWaveform = originalTxWaveform * (0.8 + 0.04 * optimalAction);
```

```
txOFDM = ofdmMod(txWaveform);
```

```
rxOFDM = channel(txOFDM);
```

```
rxWaveform = ofdmDemod(rxOFDM);
```

% Υπολογισμός και εμφάνιση αποτελεσμάτων

```
receivedPower = mean(abs(rxWaveform(:)).^2);
```

```
mse = mean(abs(originalTxWaveform(:) - rxWaveform(:)).^2);
```

```
snr = 10 * log10(mean(abs(originalTxWaveform(:)).^2) / mse);
```

```
disp(['Ισχύς        Λαμβανόμενου        Σήματος        (Q-learning):        ',  
num2str(10*log10(receivedPower)), ' dB']);
```

```
disp(['Μέσο Τετραγωνικό Σφάλμα (Q-learning): ', num2str(mse)]);
```

```
disp(['Σχέση Σήματος προς Θόρυβο (Q-learning): ', num2str(snr), ' dB']);
```

```
if reward > best_reward
```

```
    best_params = [alpha, gamma, epsilon];
```

```
    best_reward = reward;
```

```
end
```

```
end
```

```
end
```

```
end
```

```
% Σχεδίαση της κυματομορφής μετά την αποδιαμόρφωση OFDM
```

```
figure;
```

```
subplot(2, 1, 1);
```

```
plot(real(originalTxWaveform(:)));
```

```
title('Εκπεμπόμενα Σύμβολα OFDM (Q-learning)');
```

```
xlabel('Δείκτης Σύμβολου');
```

```
ylabel('Πλάτος');
```

```
grid on;
```

```
subplot(2, 1, 2);
```

```
plot(real(rxWaveform(:)));
```

```
title('Λαμβανόμενα Σύμβολα OFDM (Q-learning)');
```

```
xlabel('Δείκτης Σύμβολου');
```

```
ylabel('Πλάτος');
```

```
grid on;
```

Ο κώδικας αυτός στοχεύει στη βελτιστοποίηση της απόδοσης ενός δικτύου 5G χρησιμοποιώντας Q-learning για τη διαχείριση πόρων και αποφάσεων ελέγχου ισχύος, λαμβάνοντας υπόψη την ποιότητα του σήματος και τις συνθήκες του καναλιού.

Ο κώδικας αυτός αποτελεί μια προσομοίωση ενός συστήματος επικοινωνίας 5G που χρησιμοποιεί διαμόρφωση OFDM (Orthogonal Frequency Division Multiplexing) και τεχνικές ενισχυτικής μάθησης (Q-learning) για τη βελτιστοποίηση της απόδοσης του δικτύου. Το Q-learning χρησιμοποιείται για τη βελτιστοποίηση της απόδοσης του συστήματος OFDM σε συνθήκες καναλιού Rayleigh. Συγκεκριμένα, ο σκοπός της χρήσης του Q-learning είναι να προσαρμόσει παραμέτρους εκπομπής, όπως το επίπεδο

ισχύος ή την επιλογή συγκεκριμένων υποφορέων, με στόχο τη μεγιστοποίηση της ποιότητας του λαμβανόμενου σήματος και την ελαχιστοποίηση του σφάλματος.

Χρήση του Q-learning στον Αλγόριθμο

1. **Καταστάσεις και Ενέργειες:** Στον αλγόριθμο, κάθε κατάσταση αντιπροσωπεύει έναν υποφορέα στο φάσμα του OFDM. Οι ενέργειες μπορεί να αναφέρονται σε επίπεδα ισχύος ή άλλες ρυθμίσεις εκπομπής που επηρεάζουν το σήμα, προσαρμόζοντας έτσι την εκπομπή ώστε να μεγιστοποιηθεί η απόδοση.
2. **Πολιτική Εξερεύνησης (Epsilon-Greedy):** Με την πολιτική epsilon-greedy, ο αλγόριθμος έχει τη δυνατότητα είτε να επιλέγει τυχαία μια ενέργεια (εξερεύνηση) είτε να επιλέγει την καλύτερη γνωστή ενέργεια (εκμετάλλευση) με βάση τον πίνακα Q. Αυτό επιτρέπει στον αλγόριθμο να μάθει τις βέλτιστες δράσεις μέσα από δοκιμές και βελτιώσεις.
3. **Συνάρτηση Ανταμοιβής:** Η συνάρτηση ανταμοιβής λαμβάνει υπόψη τρεις βασικούς παράγοντες: την ισχύ του λαμβανόμενου σήματος, το μέσο τετραγωνικό σφάλμα (MSE), και τη σχέση σήματος προς θόρυβο (SNR). Ο στόχος είναι η βελτιστοποίηση αυτών των μετρικών ώστε το σύστημα να επιλέξει ενέργειες που οδηγούν στη βέλτιστη ποιότητα λήψης του σήματος.
4. **Ενημέρωση του Q-πίνακα:** Σε κάθε επεισόδιο, ο πίνακας Q ενημερώνεται με βάση την ανταμοιβή που λαμβάνει για κάθε ενέργεια, προσαρμόζοντας σταδιακά τις επιλογές για καλύτερα αποτελέσματα στο σύστημα επικοινωνίας.

Βήματα του αλγορίθμου

Ακολουθούν αναλυτικά τα βήματα του αλγορίθμου

1. Ορισμός Παραμέτρων Συστήματος

Η αρχική φάση του κώδικα περιλαμβάνει τον ορισμό κρίσιμων παραμέτρων που διέπουν τη λειτουργία του συστήματος.

matlab

$f_c = 28e9$; % Συχνότητα φορέα (28 GHz)

$bw = 100e6;$ % Εύρος ζώνης (100 MHz)
 $scs = 30e3;$ % Απόσταση μεταξύ υποφορέων (30 kHz)
 $nSubcarriers = \text{floor}(bw / scs);$ % Αριθμός υποφορέων
 $nAntennas = 64;$ % Αριθμός κεραιών (MIMO)
 $nSymbols = 14;$ % Αριθμός συμβόλων OFDM ανά πλαίσιο
 $samplingRate = nSubcarriers * scs;$ % Ρυθμός δειγματοληψίας

Ανάλυση:

- **Συχνότητα Φορέα (fc):** Η συχνότητα των 28 GHz είναι χαρακτηριστική για τις εφαρμογές 5G, προσφέροντας υψηλό εύρος ζώνης.
- **Εύρος Ζώνης (bw):** Το εύρος ζώνης 100 MHz επιτρέπει την εκπομπή πολλών υποφορέων, διευκολύνοντας την ταυτόχρονη μεταφορά δεδομένων.
- **Απόσταση Υποφορέων (scs):** Η απόσταση των 30 kHz καθορίζει την αναλογία μεταξύ των υποφορέων.
- **Αριθμός Υποφορέων (nSubcarriers):** Ο υπολογισμός του αριθμού των υποφορέων διασφαλίζει ότι οι τιμές είναι ακέραιες, επιτρέποντας τη σωστή λειτουργία της διαμόρφωσης OFDM.
- **Αριθμός Κεραιών (nAntennas):** Η επιλογή 64 κεραιών δείχνει τη δυνατότητα χρήσης τεχνολογίας MIMO, που ενισχύει τη χωρητικότητα και την αξιοπιστία του συστήματος.
- **Αριθμός Συμβόλων (nSymbols):** Ο αριθμός των συμβόλων ανά πλαίσιο επηρεάζει τον ρυθμό μετάδοσης.

2. Δημιουργία Κυματομορφής OFDM

matlab

$txWaveform = \text{complex}(\text{randn}(nSubcarriers, nSymbols), \text{randn}(nSubcarriers, nSymbols));$

Ανάλυση:

- Η κυματομορφή OFDM δημιουργείται τυχαία με τη χρήση πολύπλοκων αριθμών. Αυτή η τυχαία κυματομορφή θα υποβληθεί σε διαδικασία διαμόρφωσης και αποδιαμόρφωσης.

3. Διαμόρφωση OFDM

matlab

```
ofdmMod = comm.OFDMModulator('FFTLength', nSubcarriers,  
'NumGuardBandCarriers', [0; 0], ...  
    'CyclicPrefixLength', 72, 'NumSymbols', nSymbols);  
txOFDM = ofdmMod(txWaveform);
```

Ανάλυση:

- Η διαμόρφωση OFDM εκτελείται μέσω του αντικειμένου `comm.OFDMModulator`. Ο καθορισμός των παραμέτρων, όπως το μήκος FFT και το μήκος κυκλικού προθέματος, διασφαλίζει την ορθή εκτέλεση της διαδικασίας.

4. Ορισμός Καναλιού Rayleigh

matlab

```
channel = comm.RayleighChannel('SampleRate', samplingRate, ...  
    'PathDelays', [0 1.5e-6], 'AveragePathGains', [0 -3]);
```

Ανάλυση:

- Το κανάλι Rayleigh προσομοιώνει τις τυχαίες παραλείψεις σήματος που συμβαδίζουν με τις αστικές και ημιαστικές περιοχές. Οι καθυστερήσεις διαδρομής και οι μέσες απώλειες καθορίζουν τη συμπεριφορά του καναλιού.

5. Αποδιαμόρφωση OFDM

matlab

```
ofdmDemod = comm.OFDMDemodulator('FFTLength', nSubcarriers,  
'NumGuardBandCarriers', [0; 0], ...  
    'CyclicPrefixLength', 72, 'NumSymbols', nSymbols);  
rxOFDM = channel(txOFDM);  
rxWaveform = ofdmDemod(rxOFDM);
```

Ανάλυση:

- Η αποδιαμόρφωση OFDM ολοκληρώνεται, και οι ληφθέντες κυματομορφές υπολογίζονται. Αυτή η διαδικασία επαναφέρει την αρχική πληροφορία που εστάλη μέσω του καναλιού.

6. Υπολογισμός Ποιότητας Λαμβανόμενου Σήματος

matlab

```
receivedPower = mean(abs(rxWaveform(:)).^2);
```

```
mse = mean(abs(txWaveform(:) - rxWaveform(:)).^2);
```

```
snr = 10 * log10(mean(abs(txWaveform(:)).^2) / mse);
```

Ανάλυση:

- Ο υπολογισμός της ποιότητας του ληφθέντος σήματος περιλαμβάνει:
 - ο **Ικανότητα Λαμβανόμενου Σήματος (receivedPower):** Υπολογίζεται μέσω του μέσου τετραγωνικού της ληφθείσας κυματομορφής.
 - ο **Μέσο Τετραγωνικό Σφάλμα (mse):** Αναπαριστά τη διαφορά μεταξύ του εκπεμπόμενου και του ληφθέντος σήματος.
 - ο **Σχέση Σήματος προς Θόρυβο (SNR):** Υπολογίζεται για να προσδιορίσει την ποιότητα του σήματος.

7. Αξιολόγηση της Απόδοσης του Συστήματος

matlab

```
disp(['Ισχύς Λαμβανόμενου Σήματος: ', num2str(10*log10(receivedPower)), ' dB']);
```

```
disp(['Μέσο Τετραγωνικό Σφάλμα: ', num2str(mse)]);
```

```
disp(['Σχέση Σήματος προς Θόρυβο: ', num2str(snr), ' dB']);
```

Ανάλυση:

- Οι αξιολογήσεις των παραμέτρων της απόδοσης παρουσιάζονται μέσω της εντολής disp, επιβεβαιώνοντας την επιτυχία της διαδικασίας επικοινωνίας και παρέχοντας πληροφορίες σχετικά με την ποιότητα του ληφθέντος σήματος.

8. Γραφικές Παρουσιάσεις

Η γραφική αναπαράσταση των κυματομορφών εκπομπής και λήψης είναι κρίσιμη για την οπτική κατανόηση της απόδοσης του συστήματος:

```

matlab

figure;

subplot(2, 1, 1);

plot(real(txOFDM));

title('Εκπεμπόμενο Σήμα OFDM');

xlabel('Δείκτης Δείγματος');

ylabel('Πλάτος');

grid on;

subplot(2, 1, 2);

plot(real(rxOFDM));

title('Λαμβανόμενο Σήμα OFDM');

xlabel('Δείκτης Δείγματος');

ylabel('Πλάτος');

grid on;

```

Ανάλυση:

- Οι γραφικές παραστάσεις των εκπεμπόμενων και ληφθέντων σημάτων διευκολύνουν την ανάλυση της μετάδοσης, καταδεικνύοντας τυχόν παραμορφώσεις που προκύπτουν κατά τη διάρκεια της διαδικασίας.

9. Εφαρμογή Q-learning

Η εκπαίδευση του πράκτορα Q-learning είναι καθοριστική για τη βελτιστοποίηση της απόδοσης του δικτύου. Ο αλγόριθμος Q-learning προσαρμόζει τις ενέργειες με βάση τις παραμέτρους που ορίζονται:

```

matlab

for alpha = [0.01, 0.05, 0.1]

    for gamma = [0.5, 0.8, 0.9]

        for epsilon = [0.1, 0.2, 0.3]

```

```

        % Εκπαίδευση του πράκτορα Q-learning
        ...
    end
end
end
end

```

Ανάλυση:

- Οι υπερπαράμετροι του αλγορίθμου (alpha, gamma, epsilon) είναι κρίσιμες για την εκπαίδευση και επηρεάζουν τη στρατηγική μάθησης του πράκτορα. Ο αριθμός επεισοδίων εκπαιδεύει τον πράκτορα για να βελτιώσει την απόδοση του συστήματος σε πραγματικές συνθήκες.

10. Εξαγωγή Αποτελεσμάτων

Η εξαγωγή και ανάλυση των αποτελεσμάτων ολοκληρώνει τη διαδικασία, παρέχοντας μια σαφή εικόνα της απόδοσης του συστήματος:

```

matlab

% Εξαγωγή Αποτελεσμάτων

disp(['Ικανότητα Σήματος: ', num2str(10*log10(receivedPower)), ' dB']);

disp(['Μέσο Τετραγωνικό Σφάλμα: ', num2str(mse)]);

disp(['Σχέση Σήματος προς Θόρυβο: ', num2str(snr), ' dB']);

```

Αποτελέσματα Προσμείωσης

```

alpha= 0.05;

gamma=0.8;

epsilon=0.1;

```

Οι Παράμετροι Συστήματος Έχουν Αρχικοποιηθεί

Η Διαμόρφωση OFDM Ολοκληρώθηκε

Το Μοντέλο Καναλιού Ολοκληρώθηκε

Η Αποδιαμόρφωση OFDM Ολοκληρώθηκε

Ισχύς Λαμβανόμενου Σήματος: -0.3967 dB

Μέσο Τετραγωνικό Σφάλμα: 0.65821

Σχέση Σήματος προς Θόρυβο: 4.8104 dB

Ο Πίνακας Q που Μάθαμε:

Ισχύς Λαμβανόμενου Σήματος (Q-learning): 2.5417 dB

Μέσο Τετραγωνικό Σφάλμα (Q-learning): 0.30934

Σχέση Σήματος προς Θόρυβο (Q-learning): 8.0897 dB

Επεξήγηση αποτελεσμάτων

- **Αρχικό Σύστημα:**
 - **Ισχύς Λαμβανόμενου Σήματος:** -0.3967 dB
 - **Μέσο Τετραγωνικό Σφάλμα (MSE):** 0.65821
 - **Σχέση Σήματος προς Θόρυβο (SNR):** 4.8104 dB
- **Βελτιωμένο με Q-learning:**
 - **Ισχύς Λαμβανόμενου Σήματος (Q-learning):** 2.5417 dB
 - **Μέσο Τετραγωνικό Σφάλμα (Q-learning):** 0.30934
 - **Σχέση Σήματος προς Θόρυβο (Q-learning):** 8.0897 dB

Ισχύς Λαμβανόμενου Σήματος:

- **Αρχικό:** -0.3967 dB
- **Q-learning:** 2.5417 dB
- **Βελτίωση:** Η ληφθείσα ισχύς έχει αυξηθεί σημαντικά, υποδεικνύοντας ενισχυμένη λήψη σήματος με τη χρήση του Q-learning.

Μέσο Τετραγωνικό Σφάλμα (MSE):

- **Αρχικό:** 0.65821
- **Q-learning:** 0.30934

- ο **Βελτίωση:** Το MSE έχει μειωθεί δραστικά, δείχνοντας μεγαλύτερη ακρίβεια στην εκτίμηση του σήματος με τη χρήση του Q-learning.

Σχέση Σήματος προς Θόρυβο (SNR):

- ο **Αρχικό:** 4.8104 dB
- ο **Q-learning:** 8.0897 dB
- ο **Βελτίωση:** Το SNR έχει βελτιωθεί σημαντικά, υποδεικνύοντας καλύτερη ποιότητα σήματος με λιγότερο θόρυβο σε σχέση με την ισχύ του σήματος.

Τα αποτελέσματα δείχνουν ξεκάθαρα την αποτελεσματικότητα του Q-learning στη βελτιστοποίηση του συστήματος OFDM. Το Q-learning οδηγεί σε ισχυρότερο, ακριβέστερο και υψηλότερης ποιότητας σήμα, μειώνοντας τον θόρυβο και βελτιώνοντας την ακρίβεια του συστήματος.

Διαγράμματα και Συμπεράσματα




Figure 16 Αποτέλεσμα matlab

Εκπεμπόμενο Σήμα OFDM (Original)

- Στο διάγραμμα αυτό, παρουσιάζεται το εκπεμπόμενο σήμα OFDM, που προκύπτει από τη διαμόρφωση της κυματομορφής txWaveform. Το σήμα αυτό είναι η αρχική κυματομορφή που μεταδίδεται στο κανάλι.

Λαμβανόμενο Σήμα OFDM (Original)

- Απεικονίζεται η κυματομορφή του λαμβανόμενου σήματος μετά από την αποδιαμόρφωση OFDM. Η διαφορά μεταξύ εκπεμπόμενου και λαμβανόμενου σήματος εξαρτάται από την εξασθένηση και το θόρυβο που εισάγεται από το κανάλι Rayleigh, με αποτέλεσμα διαφοροποιήσεις στο SNR και στο MSE.




Figure 17 Αποτέλεσμα matlab

Απόκριση Παλμού Καναλιού

Εδώ, το κανάλι εξασθένησης Rayleigh ελέγχεται με την απόκριση του σε ένα κρουστικό σήμα, ώστε να παρατηρηθούν οι διακυμάνσεις του καναλιού με την πάροδο του χρόνου. Το διάγραμμα εμφανίζει την επίδραση του καναλιού στο λαμβανόμενο σήμα, επισημαίνοντας τις επιπτώσεις της πολλαπλής διαδρομής στην ισχύ σήματος.




Figure 18 Αποτέλεσμα matlab

Διάγραμμα Εκπεμπόμενων και Λαμβανόμενων Συμβόλων OFDM

Αυτά τα διαγράμματα εμφανίζουν τα σύμβολα OFDM πριν και μετά την αποδιαμόρφωση, δίνοντας μια πιο λεπτομερή ανάλυση σε επίπεδο συμβόλων.

- **Εκπεμπόμενα Σύμβολα OFDM:** Η πρώτη γραφική παράσταση παρουσιάζει την πραγματική συνιστώσα των εκπεμπόμενων συμβόλων OFDM όπως ήταν αρχικά διαμορφωμένα και πριν την παραμόρφωση στο κανάλι.
- **Λαμβανόμενα Σύμβολα OFDM:** Στην δεύτερη γραφική παράσταση βλέπουμε τα σύμβολα όπως έχουν ληφθεί μετά την αποδιαμόρφωση, όπου περιλαμβάνονται παραμορφώσεις που προκλήθηκαν από το κανάλι Rayleigh.




Figure 19 Αποτέλεσμα matlab

Σχεδίαση Εκπεμπόμενων και Λαμβανόμενων Συμβόλων OFDM (Q-learning)

1. Εκπεμπόμενα Σύμβολα OFDM (με Q-learning)

- Παρουσιάζεται η αρχική κυματομορφή του εκπεμπόμενου σήματος όπως διαμορφώθηκε στην αρχή της διαδικασίας Q-learning, αποτελώντας τη βάση για την αξιολόγηση της ποιότητας του σήματος.

2. Λαμβανόμενα Σύμβολα OFDM (με Q-learning)

- Η βέλτιστη κυματομορφή που λαμβάνεται μετά από τη διαδικασία Q-learning. Το διάγραμμα αυτό επιτρέπει τη σύγκριση της απόδοσης του σήματος πριν και μετά την εφαρμογή της στρατηγικής Q-learning, και μας επιτρέπει να αναγνωρίσουμε τις βελτιώσεις στην ποιότητα του σήματος με βάση τον Σχέση Σήματος προς Θόρυβο (SNR).

Παράδειγμα 2 εφαρμογής q-learning αλγορίθμου σε ένα δίκτυο

5G

Στο παράδειγμα αυτό θα επικεντρωθούμε στην εκπαίδευση μέσω της εξερεύνησης και της εκμετάλλευσης, αναζητώντας καλύτερες παραμέτρους. Θα προσπαθήσουμε το παράδειγμα αυτό να είναι αντιπροσωπευτικό της πραγματικότητας με ορισμένες παραμέτρους και μικρή τυχαιότητα. Επίσης θα οπτικοποιήσουμε καλύτερα το πως ο αλγόριθμος και η τεχνική Q-learning βοηθούν.

Παρέχεται ο κώδικας του Matlab

```
% Αρχικοποίηση παραμέτρων Q-learning
num_states = 100;      % Πλήθος καταστάσεων (φορτίο κυκλοφορίας, ισχύς σήματος,
                        % διαθεσιμότητα πόρων)
num_actions = 5;       % Πλήθος ενεργειών (π.χ. αλλαγές διαμόρφωσης, μετακίνηση
                        % πόρων)

% Αρχικοποίηση Q-table
q_table = zeros(num_states, num_actions); % Q-table αρχικοποίηση με μηδενικές τιμές
alpha = 0.7;           % Συντελεστής μάθησης
gamma = 0.95;          % Παράγοντας έκπτωσης
epsilon = 1.0;         % Αρχική πιθανότητα εξερεύνησης
epsilon_min = 0.01;    % Ελάχιστο epsilon
epsilon_decay = 0.999; % Σταδιακή μείωση του epsilon

% Παράμετροι προσομοίωσης
num_episodes = 20000;  % Αριθμός επεισοδίων προσομοίωσης
max_steps = 50;        % Μέγιστος αριθμός βημάτων ανά επεισόδιο

% Αρχικές τιμές απόδοσης για κάθε κατάσταση πριν το Q-learning
initial_performance = rand(num_states, 1) * 10; % Τυχαίες αρχικές αποδόσεις

% Δημιουργία αναγκαίων μεταβλητών για τη στατιστική παρακολούθηση
```

```

performance_history = zeros(num_episodes, num_states); % Ιστορικό απόδοσης για
ανάλυση
mean_reward_per_episode = zeros(num_episodes, 1); % Μέση ανταμοιβή ανά
επεισόδιο
state_visits = zeros(num_states, 1); % Ανάκτηση επισκέψεων καταστάσεων
epsilon_history = zeros(num_episodes, 1); % Ιστορικό epsilon

% Προσομοίωση Q-learning
for episode = 1:num_episodes
    state = randi(num_states); % Τυχαία αρχικοποίηση κατάστασης
    total_reward = 0; % Συγκέντρωση ανταμοιβών για το επεισόδιο

    for step = 1:max_steps
        % Επιλογή δράσης με πολιτική epsilon-greedy
        if rand < epsilon
            action = randi(num_actions); % Εξερεύνηση
        else
            [~, action] = max(q_table(state, :)); % Εκμετάλλευση
        end

        % Εκτέλεση της δράσης και μετάβαση σε νέα κατάσταση
        [new_state, reward] = simulate_5G_network(state, action, num_states,
num_actions);

        % Υπολογισμός νέας Q-τιμής
        q_table(state, action) = (1 - alpha) * q_table(state, action) + ...
            alpha * (reward + gamma * max(q_table(new_state, :)));

        % Ενημέρωση κατάστασης
        state = new_state;

        % Ενημέρωση επισκέψεων κατάστασης
        state_visits(state) = state_visits(state) + 1;
    end
end

```

```

    % Συγκέντρωση ανταμοιβών
    total_reward = total_reward + reward;
end

% Αποθήκευση απόδοσης για ανάλυση
performance_history(episode, :) = mean(q_table, 2);
mean_reward_per_episode(episode) = total_reward / max_steps; % Μέση
ανταμοιβή

% Μείωση του epsilon
if epsilon > epsilon_min
    epsilon = epsilon * epsilon_decay;
end
epsilon_history(episode) = epsilon; % Αποθήκευση τρέχοντος epsilon
end

% Τελικές τιμές απόδοσης για κάθε κατάσταση μετά το Q-learning
final_performance = mean(q_table, 2);

% Ανάλυση Πολιτικής
policy = zeros(num_states, 1);
for state = 1:num_states
    [~, policy(state)] = max(q_table(state, :)); % Καλύτερη δράση ανά κατάσταση
end

% Εμφάνιση αποτελεσμάτων πριν και μετά το Q-learning
disp('Αρχικές αποδόσεις πριν το Q-learning:');
disp(initial_performance);
disp('Τελικές αποδόσεις μετά το Q-learning:');
disp(final_performance);
disp('Ανάλυση Πολιτικής (Καλύτερες ενέργειες):');
disp(policy);

% Οπτικοποίηση βελτιώσεων

```

```

figure;
bar([initial_performance final_performance]);
xlabel('Κατηγορίες');
ylabel('Απόδοση');
legend('Πριν το Q-learning', 'Μετά το Q-learning');
title('Συγκριτική Απόδοση Δικτύου 5G πριν και μετά το Q-learning');
grid on; % Προσθέστε πλέγμα

% Οπτικοποίηση ιστορικού απόδοσης
figure;
plot(mean(performance_history, 2), 'LineWidth', 2);
hold on;
plot(mean_reward_per_episode, '--', 'LineWidth', 1.5);
xlabel('Επεισόδια');
ylabel('Μέση Απόδοση');
title('Βελτίωση της Απόδοσης Δικτύου 5G κατά τη διάρκεια της Εκπαίδευσης');
legend('Μέση Απόδοση', 'Μέση Ανταμοιβή');
grid on;

% Οπτικοποίηση ιστορικού εξερεύνησης
figure;
plot(epsilon_history, 'LineWidth', 2);
xlabel('Επεισόδια');
ylabel('Epsilon');
title('Εξέλιξη της πιθανότητας εξερεύνησης (epsilon)');
grid on;

% Συνάρτηση προσομοίωσης δικτύου 5G
function [new_state, reward] = simulate_5G_network(state, action, num_states,
num_actions)
    % Ορισμός στατιστικών στοιχείων για το 5G
    traffic_load = randi([1, 10]); % Φόρτιο κυκλοφορίας (1-10)
    signal_strength = randi([1, 10]); % Ικανότητα σήματος (1-10)
    resource_availability = randi([1, 10]); % Διαθεσιμότητα πόρων (1-10)

```

```

% Υπολογισμός ανταμοιβής βάσει KPIs
delay = (10 - traffic_load) / signal_strength; % Υπολογισμός καθυστέρησης
reward = (10 - traffic_load) + signal_strength + resource_availability - (action - 1) -
delay;

% Ανάλογα με τη δράση, προσομοιώνουμε τις μεταβάσεις
if action == 1 % Μειώστε το φορτίο
    new_state = min(state + traffic_load, num_states); % Ανάλογα με την αύξηση του
φορτίου
elseif action == 2 % Αυξήστε την ισχύ σήματος
    new_state = max(state - signal_strength, 1); % Δε μπορεί να είναι λιγότερο από 1
elseif action == 3 % Προσθέστε πόρους
    new_state = min(state + resource_availability, num_states); % Δε μπορεί να είναι
πάνω από num_states
elseif action == 4 % Αλλάξτε προσαρμογή δικτύου
    new_state = mod(state + randi([1, 5]), num_states) + 1; % Τυχαία μετάβαση
else % Κάποια άλλη δράση
    new_state = max(state - randi([1, 3]), 1); % Τυχαία μείωση της κατάστασης
end

% Ορίζουμε μία μη γραμμική τυχαία διάταξη για πιο ρεαλιστική συμπεριφορά
transition_matrix = [0.7 0.1 0.1 0.05 0.05;
    0.1 0.7 0.1 0.05 0.05;
    0.1 0.1 0.7 0.05 0.05;
    0.05 0.05 0.05 0.85 0.0;
    0.05 0.05 0.05 0.0 0.85]; % Υποθέτουμε 5 δράσεις

% Επιλογή της νέας κατάστασης με βάση την τυχαία μετάβαση
rand_value = rand();
cumulative_probability = 0;
for a = 1:num_actions
    cumulative_probability = cumulative_probability + transition_matrix(action, a);
    if rand_value < cumulative_probability

```

```

        new_state = mod(new_state + a - 1, num_states) + 1; % Διασφαλίζουμε ότι η
        νέα κατάσταση είναι έγκυρη
        break;
    end
end
end
end

```

Ανάλυση και επεξήγηση του κώδικα

```

% Αρχικοποίηση παραμέτρων
num_states = 100; % Αριθμός καταστάσεων (π.χ. διαφορετικές συνθήκες δικτύου)
num_actions = 5; % Αριθμός ενεργειών (π.χ. στρατηγικές προσαρμογής)
Q = zeros(num_states, num_actions); % Αρχικοποίηση Q-table με μηδενικές τιμές
alpha = 0.7; % Συντελεστής μάθησης
gamma = 0.95; % Παράγοντας έκπτωσης
epsilon = 1.0; % Αρχική πιθανότητα εξερεύνησης
epsilon_decay = 0.995; % Συντελεστής μείωσης του epsilon
num_episodes = 1000; % Αριθμός επεισοδίων εκπαίδευσης

```

Αρχικοποίηση παραμέτρων: Ορίζονται οι βασικές παράμετροι του αλγορίθμου Q-learning.

num_states: Ο αριθμός των διαφορετικών καταστάσεων του δικτύου, με τιμή 100, που αναπαριστά τις διαφορετικές συνθήκες.

num_actions: Ο αριθμός των διαθέσιμων στρατηγικών (δράσεων) προσαρμογής.

Q: Ο πίνακας Q αρχικοποιείται με μηδενικές τιμές, που σημαίνει ότι αρχικά δεν υπάρχει γνώση για τις αξίες των δράσεων σε κάθε κατάσταση.

alpha, gamma, epsilon: Ορίζονται οι παράμετροι μάθησης και εξερεύνησης. Το alpha ελέγχει πόσο γρήγορα ενημερώνονται οι Q-τιμές, το gamma καθορίζει την αξία των μελλοντικών ανταμοιβών, και το epsilon ελέγχει την πιθανότητα να επιλεγεί μια τυχαία δράση αντί της βέλτιστης.

epsilon_decay: Ο συντελεστής μείωσης του epsilon επιτρέπει στον αλγόριθμο να εξερευνά λιγότερο όσο προχωρά η εκπαίδευση.

num_episodes: Ο συνολικός αριθμός επεισοδίων εκπαίδευσης για την εκμάθηση των πολιτικών δράσης.

```

% Προσομοίωση Q-learning
for episode = 1:num_episodes
    state = randi(num_states); % Τυχαία επιλογή κατάστασης
    done = false; % Σημαία για τον τερματισμό του επεισοδίου
    total_reward = 0; % Αθροιστική ανταμοιβή για το επεισόδιο
    while ~done
        % Επιλογή δράσης με πολιτική epsilon-greedy
        if rand < epsilon
            action = randi(num_actions); % Τυχαία δράση (εξερεύνηση)
        else
            [~, action] = max(Q(state, :)); % Επιλογή βέλτιστης δράσης (εκμετάλλευση)
        end

        % Εκτέλεση δράσης και υπολογισμός ανταμοιβής
        [next_state, reward, done] = simulate_5G_network(state, action);
        total_reward = total_reward + reward; % Συγκέντρωση ανταμοιβής

        % Ενημέρωση Q-τιμής
        Q(state, action) = Q(state, action) + alpha * (reward + gamma *
max(Q(next_state, :)) - Q(state, action));

        state = next_state; % Μετάβαση στην επόμενη κατάσταση
    end

    % Ενημέρωση epsilon
    epsilon = epsilon * epsilon_decay; % Μείωση της πιθανότητας εξερεύνησης
end

```

Προσομοίωση Q-learning: Αυτή η ενότητα περιλαμβάνει την εκπαίδευση του αλγορίθμου μέσα από μια σειρά επεισοδίων.

Ο βρόχος for episode = 1:num_episodes επαναλαμβάνει τη διαδικασία εκπαίδευσης για τον καθορισμένο αριθμό επεισοδίων.

state = randi(num_states): Επιλέγει τυχαία μια αρχική κατάσταση.

done = false: Σημαία που ελέγχει αν το επεισόδιο έχει τερματιστεί.

`total_reward = 0`: Μεταβλητή που συγκεντρώνει την συνολική ανταμοιβή του επεισοδίου.

Επιλογή δράσης με πολιτική epsilon-greedy:

Η απόφαση για την επιλογή δράσης γίνεται με βάση την πολιτική epsilon-greedy: Αν η τυχαία τιμή είναι μικρότερη από το epsilon, επιλέγεται μια τυχαία δράση (`action = randi(num_actions)`), προκειμένου να εξερευνηθούν νέες στρατηγικές.

Διαφορετικά, επιλέγεται η δράση που μεγιστοποιεί την Q-τιμή στην τρέχουσα κατάσταση (`[~, action] = max(Q(state, :))`).

Εκτέλεση δράσης και υπολογισμός ανταμοιβής:

Η συνάρτηση `simulate_5G_network(state, action)` εκτελεί την επιλεγμένη δράση στο περιβάλλον και επιστρέφει την νέα κατάσταση (`next_state`), την ανταμοιβή (`reward`), και την κατάσταση τερματισμού (`done`).

Το `total_reward` ενημερώνεται με την αξία της ανταμοιβής που έχει ληφθεί.

Ενημέρωση Q-τιμής:

Η Q-τιμή για την τρέχουσα κατάσταση και δράση ενημερώνεται χρησιμοποιώντας την εξίσωση Bellman:

$$Q(\text{state}, \text{action}) = Q(\text{state}, \text{action}) + \alpha(\text{reward} + \gamma \max_{a'}(Q(\text{next_state}, a')) - Q(\text{state}, \text{action}))$$

Η state ενημερώνεται με την next_state, προκειμένου να συνεχιστεί η διαδικασία εκπαίδευσης στην επόμενη επανάληψη του βρόχου.

Ενημέρωση epsilon:

Η πιθανότητα εξερεύνησης μειώνεται στο τέλος κάθε επεισοδίου (`epsilon = epsilon * epsilon_decay`), ώστε ο αλγόριθμος να εστιάζει περισσότερο στην εκμετάλλευση των αποκτηθεισών γνώσεων.

% Οπτικοποίηση αποτελεσμάτων

`figure;`

`plot(1:num_episodes, total_rewards);` % Γράφημα με τις συνολικές ανταμοιβές ανά επεισόδιο

`xlabel('Επεισόδια');`

`ylabel('Συνολική Ανταμοιβή');`

title('Απόδοση του αλγορίθμου Q-learning');

Οπτικοποίηση Αποτελεσμάτων: Αυτή η ενότητα αναφέρεται στην ανάλυση της απόδοσης του αλγορίθμου μέσω γραφικής απεικόνισης.

Η εντολή `figure` δημιουργεί ένα νέο παράθυρο γραφήματος.

`plot(1:num_episodes, total_rewards)` απεικονίζει τις συνολικές ανταμοιβές που συλλέγονται σε κάθε επεισόδιο.

Οι εντολές `xlabel`, `ylabel` και `title` προσθέτουν ετικέτες στους άξονες και τίτλο στο γράφημα, διευκολύνοντας την κατανόηση των αποτελεσμάτων.

Αποτελέσματα Προσομοίωσης

Μετά την εκτέλεση του αλγορίθμου στο προγραμματιστικό περιβάλλον του matlab πήραμε τα εξής αποτελέσματα

Αρχικές αποδόσεις πριν το Q-learning	Τελικές αποδόσεις	Ανάλυση Πολιτικής
0.0177	250.5119	2
7.2188	252.3631	2
8.5344	249.4943	1
2.3439	249.9834	4
6.1189	251.2823	1
9.5658	251.5169	3
8.222	247.9817	3
3.4734	251.4115	1
1.0444	248.7523	1
8.4495	248.0058	3
3.0355	250.6501	4
4.0495	249.2643	2

4.7417	247.8655	1
1.2763	250.6251	1
4.0622	250.515	1
3.3101	248.0183	1
5.2226	248.0442	3
6.0634	250.8153	1
4.1656	249.9496	4
6.5033	249.8487	1
3.1559	248.8349	2
1.9932	248.9949	2
2.4039	248.9683	5
7.5491	247.5258	5
0.6849	248.2322	1
6.775	250.057	2
0.9518	246.1359	5
9.5141	249.7717	4
8.8584	249.5402	1
8.3401	249.4976	3
9.7741	252.7613	1
2.9093	248.7146	4
6.1548	249.1508	3
8.5842	247.7866	5

3.3143	250.2065	4
7.9983	251.7315	1
7.346	249.6566	1
0.2283	250.7963	1
9.1078	249.0888	2
5.8513	249.9966	4
3.9782	250.1576	4
2.4413	253.2754	1
7.9794	248.9388	1
1.4027	252.2172	3
1.8498	251.4542	1
8.4241	251.7569	1
7.8282	246.9591	1
9.9104	252.1125	1
0.4668	250.1574	4
7.3406	250.9314	4
2.8567	251.2503	3
7.9892	250.1584	1
3.1609	248.205	2
3.3842	249.2453	1
1.3674	251.1271	3
0.645	253.8496	2

8.0304	249.8936	4
6.9406	251.0888	1
1.2666	252.3633	1
8.4669	250.8083	1
7.5783	249.0949	3
9.2251	252.487	2
4.2399	248.2793	5
4.4127	253.9488	1
9.3881	252.5027	1
8.3477	251.783	1
6.4625	250.477	4
5.5387	250.4898	2
0.3552	251.6467	2
4.972	253.4437	1
4.6641	252.3706	3
4.774	252.4577	3
6.6678	252.9931	5
7.9145	251.7103	1
3.9965	253.0004	1
7.0447	254.5076	2
7.469	250.3068	1
6.7092	250.5364	2

2.1941	252.3077	1
6.2219	256.362	2
6.3357	251.0037	2
0.3314	252.0327	2
9.2523	249.4322	3
8.9739	253.8667	2
5.2652	252.6491	2
9.5747	250.7586	2
4.8437	251.5397	1
9.2972	251.3559	2
1.4034	253.9017	2
1.1665	252.0693	2
4.0553	250.7483	1
3.9275	249.5435	1
1.5729	251.5833	1
2.7322	251.0458	1
0.859	250.6471	4
8.1489	254.2112	3
0.6576	251.3961	3
5.9344	246.7917	1
0.1267	251.7912	3
4.3033	250.1376	3

Πίνακας {1} Αποτελέσματα προσομοίωσης στο υπολογιστικό περιβάλλον του Matlab.




Figure 20 Αποτέλεσμα matlab




Figure 21 Αποτέλεσμα matlab




Figure 22 Αποτέλεσμα matlab

Ανάλυση Αποτελεσμάτων - Θεωρία

1 Αρχικές και Τελικές Τιμές Απόδοσης

- **Αρχικές Τιμές:** Αυτές οι τιμές είναι τυχαία καθορισμένες πριν την εφαρμογή του Q-learning και αντιπροσωπεύουν την απόδοση των διαφόρων καταστάσεων σε ένα μη βελτιστοποιημένο δίκτυο. Η τυχειότητα οφείλεται στην αρχικοποίηση και δεν αντανακλά κάποια συγκεκριμένη πολιτική απόδοσης.
- **Τελικές Τιμές:** Μετά την εκπαίδευση, οι τιμές αυτές δείχνουν τη βελτίωση απόδοσης για κάθε κατάσταση, έχοντας υιοθετηθεί η βέλτιστη πολιτική δράσης. Ο πίνακας Q έχει ενημερωθεί με γνώμονα τις ανταμοιβές που προέκυψαν από τις διάφορες ενέργειες, και έτσι οι τελικές τιμές αντικατοπτρίζουν τις καλύτερες δυνατές αποφάσεις σε κάθε κατάσταση.

2 Μέση Απόδοση και Ανταμοιβή Ανά Επεισόδιο

- Η **Μέση Απόδοση** ανά επεισόδιο προκύπτει από τον μέσο όρο των τιμών στον πίνακα Q για κάθε κατάσταση, γεγονός που αντικατοπτρίζει την βελτίωση των αποφάσεων του πράκτορα. Η σταδιακή αύξηση της μέσης απόδοσης δείχνει ότι ο πράκτορας μαθαίνει να επιλέγει ενέργειες που βελτιώνουν την απόδοση του δικτύου.
- Η **Μέση Ανταμοιβή** ανά επεισόδιο απεικονίζει τις άμεσες επιδράσεις των ενεργειών που πραγματοποιούνται. Καθώς τα επεισόδια εξελίσσονται, η ανταμοιβή αυξάνεται, δείχνοντας ότι οι επιλεγμένες ενέργειες αποφέρουν βελτιστοποιημένες τιμές KPIs, όπως χαμηλή καθυστέρηση και υψηλή διαθεσιμότητα πόρων.

3 Ιστορικό του Epsilon (Εξερεύνηση-Εκμετάλλευση)

- ο Η εξέλιξη του epsilon απεικονίζει τη μετάβαση του πράκτορα από την εξερεύνηση (έρευνα νέων ενεργειών) στην εκμετάλλευση (εφαρμογή των καλύτερων ενεργειών). Η τιμή epsilon ξεκινά από υψηλή τιμή και σταδιακά μειώνεται, καθώς ο πράκτορας συγκεντρώνει γνώση για το περιβάλλον.

- ο Αυτή η στρατηγική επιτρέπει στον αλγόριθμο να εξερευνήσει νέες ενέργειες κατά την αρχική εκπαίδευση και να εστιάσει στη βέλτιστη πολιτική καθώς μειώνεται το ϵ , οδηγώντας σε πιο σταθερά και βέλτιστα αποτελέσματα στο τέλος της εκπαίδευσης.

4 Ανάλυση Πολιτικής (Καλύτερες Ενέργειες)

Η τρίτη στήλη (Ανάλυση Πολιτικής) δείχνει τον δείκτη της βέλτιστης ενέργειας που προτείνεται για κάθε κατάσταση μετά την εκπαίδευση του αλγορίθμου. Η διαδικασία επιλογής της κατάλληλης δράσης βασίζεται στη μέγιστη προσδοκώμενη ανταμοιβή για κάθε συγκεκριμένη κατάσταση.

Η ανάλυση πολιτικής αναφέρει για κάθε κατάσταση την ενέργεια με την υψηλότερη αναμενόμενη απόδοση. Με βάση τις ενέργειες που περιλαμβάνονται (όπως η μείωση του κυκλοφοριακού φορτίου ή η προσαρμογή της ισχύος σήματος), μπορούμε να συμπεράνουμε ποιες ενέργειες προκρίνονται ως οι βέλτιστες ανά κατάσταση.

Αυτή η πολιτική είναι το αποτέλεσμα της μάθησης του αλγορίθμου και δείχνει ποια δράση μεγιστοποιεί τις ανταμοιβές για κάθε κατάσταση, π.χ., αν πρέπει να προσαρμοστεί το σήμα ή να διατεθούν επιπλέον πόροι σε κατάσταση υψηλού κυκλοφοριακού φορτίου.

Οπτικοποίηση και Σύγκριση Αποτελεσμάτων

- Η οπτικοποίηση της απόδοσης πριν και μετά το Q-learning σε γραφική μορφή δείχνει άμεσα την αποτελεσματικότητα του αλγορίθμου, αποκαλύπτοντας σημαντικές βελτιώσεις στην απόδοση του δικτύου.
- Η οπτικοποίηση της μέσης απόδοσης και της μέσης ανταμοιβής ανα επεισόδιο καταδεικνύει την πρόοδο που γίνεται κατά τη διάρκεια της εκπαίδευσης, όπου η απόδοση σταθεροποιείται σε υψηλότερες τιμές προς το τέλος των επεισοδίων.
- Τέλος, η οπτικοποίηση της τιμής ϵ παρουσιάζει το πώς η εξερεύνηση του πράκτορα μειώνεται καθώς επικεντρώνεται στην εφαρμογή των βέλτιστων ενεργειών.

Ερμηνεία των Αποτελεσμάτων - Συμπεράσματα

1. **Βελτίωση Απόδοσης:**

- ο Στις περισσότερες περιπτώσεις, η τελική απόδοση για κάθε κατάσταση έχει βελτιωθεί αισθητά σε σχέση με την αρχική τιμή, γεγονός που υποδεικνύει ότι ο αλγόριθμος Q-learning έχει βρει πιο αποτελεσματικές στρατηγικές για κάθε κατάσταση.
- ο Παραδείγματος χάριν, στην κατάσταση με αρχική απόδοση 0.0177, η τελική απόδοση αυξήθηκε σε 250.5119, και η βέλτιστη ενέργεια που επιλέχθηκε για την κατάσταση αυτή είναι η 2, υποδηλώνοντας ότι η ενέργεια αυτή μεγιστοποιεί τις ανταμοιβές.

2. Ενδείξεις Σταθερότητας:

- ο Η συνεπής αύξηση των αποδόσεων δείχνει ότι ο αλγόριθμος έχει καταλήξει σε μια σταθερή πολιτική για την εκάστοτε κατάσταση, αποφεύγοντας την επανεκπαίδευση ή την ανανέωση των αποφάσεων χωρίς λόγο.
- ο Καθώς η πολιτική σταθεροποιείται, ο πράκτορας τείνει να εκμεταλλευτεί τις καλύτερες ενέργειες που έχει μάθει για κάθε κατάσταση, οδηγώντας σε αποδοτικότερη διαχείριση των πόρων του συστήματος.

3. Ενέργειες με Υψηλότερη Απόδοση:

- ο Παρατηρούμε ότι σε αρκετές καταστάσεις η ίδια ενέργεια προτείνεται ως βέλτιστη (π.χ., η ενέργεια 1 ή 2), υποδεικνύοντας ότι αυτές οι ενέργειες έχουν ισχυρότερη επίδραση στην βελτίωση της απόδοσης σε σύγκριση με άλλες επιλογές.
- ο Η ενέργεια 1, για παράδειγμα, φαίνεται να είναι η βέλτιστη επιλογή για πλήθος καταστάσεων στις οποίες η τελική απόδοση έχει αυξηθεί σημαντικά, κάτι που υποδεικνύει πως η συγκεκριμένη δράση έχει ευρεία και θετική επίδραση στο σύστημα.

4. Προσαρμοστικότητα του Αλγορίθμου:

- ο Το γεγονός ότι σε ορισμένες καταστάσεις επιλέγονται διαφορετικές ενέργειες δείχνει την προσαρμοστικότητα του Q-learning να εξερευνά και να εκμεταλλεύεται διάφορες στρατηγικές ανάλογα με την κατάσταση.

- Για παράδειγμα, στην κατάσταση με αρχική απόδοση 9.9104, η τελική απόδοση βελτιώθηκε σε 252.1125, με την ενέργεια 1 ως βέλτιστη, ενώ σε άλλη περίπτωση η ενέργεια 5 ήταν η κατάλληλη σε κατάσταση με αρχική απόδοση 2.4039. Αυτό δείχνει ότι ο αλγόριθμος προσαρμόζει τις ενέργειές του σε διαφορετικές καταστάσεις για μέγιστη απόδοση.

5. Συνολική Βελτίωση:

- Η συνολική διακύμανση μεταξύ αρχικών και τελικών αποδόσεων για όλες τις καταστάσεις δείχνει την ισχύ της μεθόδου Q-learning στην ανακάλυψη βέλτιστων ενεργειών που αυξάνουν την απόδοση του συστήματος και βελτιώνουν την αποδοτικότητα.
- Η διαδικασία αυτή παρέχει στον πράκτορα μια ικανότητα προσαρμογής και βελτίωσης, κάτι που είναι ιδανικό για το περιβάλλον των δικτύων 5G, όπου η βέλτιστη διαχείριση πόρων είναι κρίσιμη.

Συμπεράσματα

Αποτελεί ένα αντιπροσωπευτικό παράδειγμα της πραγματικότητας για τους παρακάτω λόγους:

1. Διαχείριση Δεδομένων σε Πραγματικό Χρόνο:

- Στη λειτουργία ενός δικτύου 5G, οι συνθήκες (φορτίο κυκλοφορίας, ισχύς σήματος) μεταβάλλονται συνεχώς. Ο Q-learning μπορεί να προσαρμοστεί σε αυτές τις μεταβολές, ενισχύοντας την ικανότητα λήψης αποφάσεων σε πραγματικό χρόνο.

2. Δυναμική Εκμάθηση και Βελτιστοποίηση:

- Η ικανότητα του Q-learning να εξερευνά και να εκμεταλλεύεται τις γνώσεις του είναι κρίσιμη για την επίτευξη βέλτιστων επιδόσεων. Οι αλληλεπιδράσεις με τις παραμέτρους του δικτύου δημιουργούν έναν κύκλο εκμάθησης που είναι ευρέως εφαρμόσιμος σε περιβάλλοντα με αβέβαιες καταστάσεις.

3. Σύνθετοι Παράγοντες Απόδοσης:

- ο Οι αλληλεπιδράσεις μεταξύ των παραμέτρων της δικτυακής απόδοσης αναπαρίστανται μέσω της Q-table και της προσομοίωσης της συνάρτησης. Αυτή η πολυπλοκότητα είναι χαρακτηριστική της πραγματικότητας που αντιμετωπίζουν οι μηχανικοί δικτύων.

4. Αξιολόγηση και Βελτίωση Πολιτικών:

- ο Η ανάλυση της τελικής πολιτικής επιτρέπει στους ερευνητές και τους μηχανικούς να αξιολογούν και να βελτιώνουν τις στρατηγικές προσαρμογής του δικτύου, συμβάλλοντας στην πρόοδο και την ανάπτυξη των δικτύων 5G.

Βιβλιογραφία

- Agrawal, R., & Srikant, R. (1994). Fast algorithms for mining association rules. *Proceedings of the 20th International Conference on Very Large Data Bases*, (σσ. 487-499).
- Bellman, R. (1957). *Dynamic Programming*. Princeton University Press.
- Bello, I., Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2021). Reinforcement learning with competitive ensembles of information-constrained primitives. *IEEE Transactions on Neural Networks and Learning Systems*, σσ. 32(2), 638-650.
- Ben-David, S., Blitzer, J., Crammer, K., & Pereira, F. (2007). Analysis of representations for domain adaptation. *Advances in Neural Information Processing Systems*, σ. Vol. 19.
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, σσ. 13, 281-305.
- Bertsekas, D. P., & Tsitsiklis, J. N. (2016). *Dynamic Programming and Optimal Control (4th ed.)*. Athena Scientific.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Brown, M., Lee, K., & Tran, D. (2022). Health concerns and the 5G millimeter wave radiation. *Journal of Public Health*, σσ. 15(7), 203-214.
- Chen, H., Yu, W., & Li, X. (2021). Telemedicine and health care in the age of 5G. *Journal of Medical Systems*, σσ. 45(8), 102-112.
- Chen, J., & Kim, E. (2023). Digital inclusion and the role of 5G in remote areas. *IEEE Communications Magazine*, σσ. 61(2), 105-120.
- Chen, L., & Liu, Y. (2023). Energy optimization in 5G networks with Q-learning. *Journal of Network Efficiency*, σσ. 35(3), 89-102.
- Choudhury, R., Singh, P., & Wang, H. (2021). Infrastructure costs of 5G networks in developing areas. *Telecommunications Policy*, σσ. 49(4), 337-349.

- Davies, D. L., & Bouldin, D. W. (1979). A cluster separation measure. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, $\sigma\sigma$. 1(2), 224-227.
- Degrís, T., Pilarski, P. M., & Sutton, R. S. (2012). Model-free reinforcement learning with continuous state and action spaces. *Proceedings of the 29th International Conference on Machine Learning*, ($\sigma\sigma$. 1039-1046).
- Dua, D., & Graff, C. (2019). *UCI Machine Learning Repository*. University of California, Irvine, School of Information and Computer Sciences.
- Ester, M., Kriegel, H. P., Sander, J., & Xu, X. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. *Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining*, ($\sigma\sigma$. 226-231).
- Friedman, J., Hastie, T., & Tibshirani, R. (2001). *The elements of statistical learning: Data mining, inference, and prediction*. Springer.
- Gao, X., Zhang, Q., & Zhao, H. (2022). Interference coordination in dense 5G environments. *IEEE Transactions on Communications*, $\sigma\sigma$. 68(4), 254-262.
- Geman, S., Bienenstock, E., & Doursat, R. (1992). Neural networks and the bias/variance dilemma. *Neural Computation*, $\sigma\sigma$. 4(1), 1-58.
- Géron, A. (2017). *Hands-on machine learning with Scikit-Learn and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Guyon, I., & Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research*, $\sigma\sigma$. 3, 1157-1182.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction (2nd ed.)*. Springer.
- Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, $\sigma\sigma$. 313(5786), 504-507.
- Hodge, V. J., & Austin, J. (2004). A survey of outlier detection methodologies. *Artificial Intelligence Review*, $\sigma\sigma$. 22(2), 85-126.

- Huang, T., & Yang, Z. (2023). Seamless handover optimization using Q-learning in 5G. *Mobile Networks Journal*, σσ. 21(1), 12-20.
- Hubert, L., & Arabie, P. (1985). Comparing partitions. *Journal of Classification*, σσ. 2(1), 193-218.
- Jain, A. K., Murty, M. N., & Flynn, P. J. (1999). Data clustering: A review. *ACM Computing Surveys (CSUR)*, σσ. 31(3), 264-323.
- Jolliffe, I. T. (2002). *Principal Component Analysis*. Springer Series in Statistics.
- Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, σσ. 374(2065), 20150202.
- Karypis, G., & Han, E. H. (2000). Cliff clustering: A high-dimensional clustering algorithm. *IEEE Transactions on Knowledge and Data Engineering*, σσ. 12(4), 619-635.
- Kim, S., Park, H., & Lee, D. (2022). 5G and virtual reality: A study of user interaction and streaming quality. *IEEE Transactions on Multimedia*, σσ. 69(3), 215-229.
- Lee, J., Seo, H., & Noh, S. (2019). Q-learning for dynamic resource allocation in 5G networks. *2019 IEEE Global Communications Conference*.
- Lee, K., & Park, J. (2022). QoS optimization for real-time applications in 5G networks. *Advanced Telecommunications Systems*, σσ. 9(2), 77-89.
- Lee, S., Kim, H., & Yoon, J. (2023). Cybersecurity in 5G networks: A review of protocols and threat models. *IEEE Transactions on Network Security*, σσ. 29(8), 440-451.
- Li, X., & Zhang, Y. (2022). Spectrum allocation strategies in 5G: Balancing efficiency and fairness. *IEEE Wireless Communications*, σσ. 29(3), 285-295.
- Li, X., Ma, J., Zhang, Y., Wu, Q., & Zeng, Z. (2020). A review of applications in 5G networks: Mechanisms, issues, and emerging trends. *IEEE Network*, σσ. 34(1), 91-97.

- Li, Y., Chen, M., Al-Shalash, Y., & Poor, H. V. (2015). QoE-driven resource allocation for heterogeneous networks: A deep reinforcement learning perspective. *IEEE Journal on Selected Areas in Communications*, σσ. 2464-2476.
- Li, Z., Gao, M., & Wu, F. (2023). Applications of 5G V2X communication in autonomous vehicles. *IEEE Transactions on Intelligent Transportation Systems*, σσ. 14(5), 330-345.
- Lipton, Z. C. (2016). The mythos of model interpretability. *Communications of the ACM*, σσ. 61(3), 36-43.
- Liu, F. T., Ting, K. M., & Zhou, Z. H. (2008). Isolation forest. *2008 Eighth IEEE International Conference on Data Mining*, (σσ. 413-422).
- Liu, L., Chen, S., Tong, Q., & Li, G. Y. (2018). Deep reinforcement learning for dynamic resource allocation in OFDMA systems. *IEEE Journal on Selected Areas in Communications*, σσ. 37(4), 737-751.
- Liu, X., & Zhang, L. (2021). Frequency band utilization in 5G networks. *Wireless Networks Journal*, σσ. 112-129.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. In *Advances in Neural Information Processing Systems*, σσ. pp. 4765-4774.
- MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, (σσ. Vol. 1, pp. 281-297).
- Mao, H., Alizadeh, M., Menache, I., & Kandula, S. (2017). Resource management with deep reinforcement learning. *Proceedings of the 15th ACM Workshop on Hot Topics in Networks*, (σσ. 50-56).
- Mnih, V., Kavukcuoglu, K., Silver, D., Rummery, G., & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, σσ. 518(7540), 529-533.
- Morocho-Cayamcela, Lee, M.E., & W.Lim. (2018). Artificial Intelligence in 5G Technology: A Survey. *2018 International Conference on Information and Communication Technology Convergence (ICTC)*.

- Morocho-Cayamcela, M. E., Lee, H., & Lim, W. (2020). Machine Learning for 5G/B5G Mobile and Wireless Communications: Potential, Limitations and Future Directions. *IEEE Access*.
- Murtagh, F., & Contreras, P. (2012). Algorithms for hierarchical clustering: An overview. *WIREs Data Mining and Knowledge Discovery*, $\sigma\sigma$. 2(1), 86-97.
- Ng, A. Y. (2004). Feature selection, L1 vs. L2 regularization, and rotational invariance. *Proceedings of the Twenty-first International Conference on Machine Learning*, ($\sigma\sigma$. 78-85).
- Park, Y., Lee, K., & Kim, J. Y. (2021). 5G URLLC for Industrial IoT Applications: Opportunities and Challenges. *IEEE Communications Magazine*, $\sigma\sigma$. 59(7), 16-23.
- Quinonero-Candela, J., Sugiyama, M., Schwaighofer, A., & Lawrence, N. D. (2009). Dataset shift in machine learning. *Machine Learning*, $\sigma\sigma$. 77(1), 287-310.
- Rand, W. M. (1971). Objective criteria for the evaluation of clustering methods. *Journal of the American Statistical Association*, $\sigma\sigma$. 66(336), 846-850.
- Rousseeuw, P. J. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, $\sigma\sigma$. 20, 53-65.
- Russell, S., & Norvig, P. (2010). *Artificial Intelligence: A Modern Approach (3rd ed.)*. Pearson.
- Samarakoon, M., Bennis, M., & Latva-aho, M. (2019). Machine learning for future wireless networks: Overview, applications, and challenges. *IEEE Communications Surveys & Tutorials*, $\sigma\sigma$. 21(3), 2380-2415.
- Schölkopf, B., Smola, A. J., Williamson, R. C., & Ba, J. (2001). Novelty detection: A review—statistical and computational approaches. *Neural Computation*, $\sigma\sigma$. 13(7), 1453-1481.
- Shimodaira, H. (2000). Improving predictive inference under covariate shift by weighting the log-likelihood function. *Journal of Statistical Planning and Inference*, $\sigma\sigma$. 90(2), 227-245.

- Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical Bayesian optimization of machine learning algorithms. *In Advances in Neural Information Processing Systems*, σσ. 2951-2959.
- Sun, Y., Huang, J., & Wang, L. (2022). Remote patient monitoring through 5G connectivity. *Journal of Health Informatics*, σσ. 33(6), 520-529.
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction (2nd ed.)*. MIT Press.
- Tariq, F., Khandaker, M., Wong, K., Imran, M., Bennis, M., & Debbah, M. (2021). A speculative study on 6G. *IEEE Communications Standards Magazine*, pp. 5(1), 10-18.
- van der Maaten, L., & Hinton, G. (2008). Visualizing high-dimensional data using t-SNE. *Journal of Machine Learning Research*, σσ. 9(86), 2579-2605.
- Wang, J., Wu, Y., & Zhang, S. (2022). Machine learning for 5G and beyond: Opportunities, challenges, and future directions. *IEEE Network*, σσ. 148-155.
- Wang, K., Zhang, Y., & Tan, L. (2021). Industrial IoT: 5G and the future of smart factories. *International Journal of Production Research*, σσ. 59(14), 4021-4035.
- Wang, S., Han, Z., Chen, C., & Yang, L. (2019). Deep learning for intelligent wireless networks: A comprehensive survey. *IEEE Communications Surveys & Tutorials*, σσ. 929-976.
- Wu, M., Liu, F., & Chen, Z. (2021). Load balancing using Q-learning in cellular networks. *International Journal of Network Management*, σσ. 30(7), 401-410.
- Xiong, Y., & Zhao, Q. (2023). Software-defined networking and virtual network functions in 5G. *Journal of Network Management*, σσ. 19(6), 356-370.
- Yang, R., & Zhou, H. (2022). Small cells and base stations in 5G deployment. *Communications Technology*, σσ. 27(3), 211-223.
- Zhang, C., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. (2021). Understanding deep learning (still) requires rethinking generalization. *Communications of the ACM*, σσ. 64(3), 107-115.

- Zhang, L., Wu, M., & Li, Z. (2023). Social impact of 5G on public health and education. *Social Sciences Research*, σσ. 11(5), 78-92.
- Zhao, H., & Lin, J. (2022). Dynamic spectrum allocation with Q-learning in 5G. *Wireless Communications Journal*, σσ. 16(5), 123-131.
- Zhou, H., Fang, X., & Yao, L. (2020). High data rate communication in 5G networks. *IEEE Transactions on Communications*, σσ. 38(4), 251-258.