



ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ

ΤΜΗΜΑ ΨΗΦΙΑΚΩΝ ΣΥΣΤΗΜΑΤΩΝ

ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ
**ΤΕΧΝΟΟΙΚΟΝΟΜΙΚΗ ΔΙΟΙΚΗΣΗ ΤΗΛΕΠΙΚΟΙΝΩΝΙΑΚΩΝ
ΣΥΣΤΗΜΑΤΩΝ**

ΜΕΤΑΠΤΥΧΙΑΚΗ ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
**ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΚΑΙ ΜΗΧΑΝΙΚΗ
ΜΑΘΗΣΗ ΣΤΑ ΑΣΥΡΜΑΤΑ ΔΙΚΤΥΑ
ΕΠΟΜΕΝΗΣ ΓΕΝΙΑΣ**

ΑΝΔΡΩΝΗΣ ΧΡΗΣΤΟΣ – ΑΜ: 1801

ΕΠΙΒΛΕΠΟΥΣΑ: Καθηγήτρια κ. Αλεξίου Αγγελική

Πειραιάς, 2021

Περιεχόμενα

1	Εισαγωγή	6
1.1	Σκοπός της Εργασίας	12
2	Θεωρητικό Πλαίσιο	13
2.1	Τεχνητή Νοημοσύνη	13
2.1.1	Τύπος 1	13
2.1.2	Τύπος 2 (με βάση λειτουργίες)	14
2.2	Μηχανική Εκμάθηση	15
3	Δίκτυα 6G με Τεχνητή Νοημοσύνη.....	19
3.1	Το Πλαίσιο των Συστημάτων 6G.....	19
3.2	Νέες Υπηρεσίες και Απαιτήσεις	21
3.2.1	Ολογραφικές εφαρμογές.....	21
3.2.2	Ευφύης κατασκευή	22
3.2.3	Έξυπνα περιβάλλοντα.....	22
3.2.4	Αλληλεπιδράσεις εγκεφάλου-υπολογιστή.....	23
3.2.5	Επέκταση κάλυψης 3D	23
3.3	Νέες Τεχνολογίες Πρόσβασης	24
3.3.1	Επικοινωνία Terahertz	24
3.3.2	Επικοινωνία ορατού φωτός.....	24
3.3.3	Ολογραφική ραδιοσυχνότητα	25
3.3.4	Έξυπνη διεπαφή ραδιοσυχνότητας	26
3.3.5	Αρχιτεκτονική δικτύου εγγενούς ΑΙ.....	26
4	Παράγοντες που επιρρεάζουν την ανάπτυξη των Δικτύων 6G με Τεχνητή Νοημοσύνη	28
4.1	Προβλήματα μοντελοποίησης.....	28
4.2	Αποτελεσματική και γρήγορη επεξεργασία σήματος	28
4.3	Περιορισμός του υπάρχοντος ασύρματου συστήματος	29

4.4	Διαφορετικές απαιτήσεις QoS / QoE	29
4.5	Σύνθετα και ευέλικτα δίκτυα.....	30
4.6	Αποτελεσματική χρήση πόρων	31
4.7	Χαμηλότερη κατανάλωση ενέργειας	32
4.8	Αύξηση της ασφάλειας και απειλών απορρήτου	32
5	Τελευταίες Εξελίξεις της Τεχνητής Νοημοσύνης.....	34
5.1	Μηχανική Εκμάθηση	34
5.1.1	Εποπτευόμενη μάθηση.....	35
5.1.2	Μη εποπτευόμενη μάθηση.....	37
5.1.3	Semi-supervised learning	39
5.1.4	Μάθηση ενίσχυσης	39
5.2	Βαθιά Μάθηση	40
5.2.1	Πολυεπίπεδο perceptron	43
5.2.2	Δίκτυο βαθιάς πεποίθησης.....	43
5.2.3	Αυτόματος κωδικοποιητής.....	44
5.2.4	Συνελκτικό νευρικό δίκτυο	44
5.2.5	Επαναλαμβανόμενο νευρικό δίκτυο	45
5.2.6	Γενετικό δίκτυο αντιπαραθέσεων	45
5.2.7	Μάθηση βαθιάς ενίσχυσης	46
6	Ενισχυμένα με Τεχνητή Νοημοσύνη Δίκτυα.....	47
6.1	Advanced Wireless Interface	47
6.1.1	Εκτίμηση και ανίχνευση καναλιών.....	47
6.1.2	Αναγνώριση διαμόρφωσης	48
6.1.3	Αποκωδικοποίηση καναλιού.....	49
6.1.4	Βελτιστοποίηση ασύρματου από άκρο σε άκρο	50
6.2	Έξυπνος Έλεγχος Κίνησης.....	52
6.2.1	Ταξινόμηση και πρόβλεψη κυκλοφορίας	52

6.2.2	Προσωρινή αποθήκευση κίνησης	53
6.2.3	Έξυπνη δρομολόγηση	55
6.3	Διαχείριση και Ενορχήστρωση Δικτύου	58
6.3.1	Διαχείριση ασύρματων πόρων	58
6.3.2	Διαχείριση QoS και QoE	59
6.4	Βελτιστοποίηση Δικτύου	60
6.5	Ασφάλεια Δικτύου	61
7	Βιομηχανική τυποποίηση και έργα	63
7.1	Πρωτοβουλίες τυποποίησης.....	63
7.1.1	3GPP	63
7.1.2	ITU.....	63
7.1.3	ETSI.....	64
7.1.4	ISO / IEC.....	64
7.1.5	TM.....	65
7.1.6	CCSA	65
7.2	Σημαντική έρευνα και πρακτικές της βιομηχανίας.....	65
7.2.1	SELFNET	65
7.2.2	CogNet	66
7.2.3	SLICENET.....	66
7.2.4	5G-CLARITY	67
7.2.5	ARIADNE.....	67
7.2.6	MonB5G	68
8	Προτάσεις για Μελλοντική Έρευνα	69
8.1	Σύνολο δεδομένων υψηλής ποιότητας από δίκτυα κινητής τηλεφωνίας	69
8.2	Έξυπνη Ασφάλεια Δικτύου	70
8.3	Ολιστική Βελτιστοποίηση Δικτύου.....	71
8.4	Κατανεμημένη Πληροφόρηση σε Πραγματικό Χρόνο.....	72

8.5	Επαλήθευση μέσω πρακτικής εφαρμογής.....	73
9	Συμπεράσματα	75
	Βιβλιογραφία	76

1 Εισαγωγή

Τα δίκτυα ασύρματης επικοινωνίας πέμπτης γενιάς (5G) τυποποιούνται και αναπτύσσονται παγκοσμίως από το 2020. Τρία μεγάλα σενάρια επικοινωνίας του 5G είναι η βελτιωμένη ευρυζωνική κινητή τηλεφωνία, οι μαζικές επικοινωνίες τύπου μηχανής και οι εξαιρετικά αξιόπιστες επικοινωνίες χαμηλού λανθάνοντος χρόνου. Οι βασικές δυνατότητες περιλαμβάνουν ρυθμό δεδομένων αιχμής 20 Gbps, ρυθμό δεδομένων 0,1 Gbps με εμπειρία χρήστη, λανθάνοντα χρόνο από άκρο σε άκρο 1 ms, υποστήριξη κινητικότητας 500 km / h, 1 εκατομμύρια συσκευές / πυκνότητα σύνδεσης km², χωρητικότητα κυκλοφορίας περιοχής 10 Mbps / m², 3 φορές μεγαλύτερη απόδοση φάσματος και 100 φορές ενεργειακή απόδοση σε σύγκριση με τα συστήματα ασύρματης επικοινωνίας τέταρτης γενιάς (4G). Έχουν προταθεί διάφορες βασικές τεχνολογίες όπως το κύμα χιλιοστών (mm Wave) , η τεράστια πολλαπλών εισόδου και πολλαπλών εξόδων κεραία (massive MIMO) και το εξαιρετικά πυκνό δίκτυο για την επίτευξη του στόχου του 5G (Wang et al, 2014).

Ωστόσο, το 5G δεν θα πληροί όλες τις απαιτήσεις του μέλλοντος το 2030+. Οι ερευνητές αρχίζουν τώρα να επικεντρώνονται στα δίκτυα ασύρματης επικοινωνίας έκτης γενιάς (6G). Ένα από τα κύρια χαρακτηριστικά που διακρίνει το 5G είναι η χαμηλή καθυστέρηση ή ειδικότερα η εγγυημένη (ντετερμινιστική) λανθάνουσα κατάσταση, η οποία χρειάζεται ντετερμινιστική δικτύωση για να εγυηθεί την καθυστέρηση από άκρο σε άκρο με ακρίβεια και ακρίβεια που απαιτούν οι μελλοντικές περιπτώσεις χρήσης. Το 6G θα έχει πρόσθετες απαιτήσεις ακρίβειας συγχρονισμού υψηλού χρόνου και φάσης πέρα από αυτό που μπορεί να προσφέρει το 5G. Επιπρόσθετα, το 6G θα πρέπει να παρέχει σχεδόν 100% γεωγραφική κάλυψη, ακρίβεια γεω-τοποθεσίας κάτω από το εκατοστόμετρο και ρυθμό ενημέρωσης γεωγραφικής θέσης χιλιοστών του δευτερολέπτου για να ικανοποιεί τις περιπτώσεις χρήσης. Δεδομένου ότι τα δίκτυα 5G εξακολουθούν να περιορίζονται σε ορισμένα τυπικά σενάρια, απομακρυσμένες περιοχές όπως χωριά και αυτοκινητόδρομοι δεν καλύπτονται καλά, γεγονός που περιορίζει ορισμένες εφαρμογές, όπως οχήματα χωρίς οδηγό. Απαιτούνται μη επίγεια και ειδικά δορυφορικά δίκτυα επικοινωνίας για να συμπληρώσουν τα επίγεια δίκτυα για οικονομικά αποδοτική, απρόσκοπτη και πανταχού διαθέσιμη διαθεσιμότητα υπηρεσιών. Το δίκτυο επικοινωνίας μη επανδρωμένων εναέριων οχημάτων (UAV) είναι σημαντικό για γρήγορη απόκριση σε σκληρά και δύσκολα περιβάλλοντα. Το δίκτυο θαλάσσιων επικοινωνιών είναι

απαραίτητο για την παροχή υπηρεσιών επικοινωνίας υψηλής ποιότητας στα πλοία. Ενώ το mm Wave μπορεί να παρέχει ρυθμό μετάδοσης επιπέδου Gbps σε 5G, θα χρειαστεί ρυθμός μετάδοσης επιπέδου Tbps για εφαρμογές όπως υψηλής ποιότητας τρισδιάστατο (3D) βίντεο, εικονική πραγματικότητα (VR) και συνδυασμό VR και επαυξημένης πραγματικότητας (AR), όπου terahertz (THz) και οπτικές ζώνες συχνοτήτων μπορούν να είναι υποψήφιες ζώνες. Αντιμετωπίζοντας τα μεγάλα σύνολα δεδομένων που δημιουργούνται χρησιμοποιώντας εξαιρετικά ετερογενή δίκτυα, διαφορετικά σενάρια επικοινωνίας, μεγάλο αριθμό κεραιών, ευρεία ζώνη εύρους ζώνης και νέες απαιτήσεις υπηρεσίας, τα δίκτυα 6G θα επιτρέψουν μια νέα σειρά έξυπνων εφαρμογών με τη βοήθεια της τεχνητής νοημοσύνης (AI) και του μηχανήματος τεχνολογίας μάθησης (ML). Ένα επίπεδο αυτοματισμού είναι για τη βελτίωση της ίδιας της απόδοσης του δικτύου σε πολλές πτυχές, για παράδειγμα, ποιότητα υπηρεσίας (quality of service), ποιότητα εμπειρίας (quality of experience), ασφάλεια, διαχείριση σφαλμάτων και ενεργειακή απόδοση.

Έως 5G, η κυκλοφορία στο δίκτυο κυριαρχείται από εφαρμογές βίντεο ή ροής. Εκτός από όλες τις εφαρμογές και τις απαιτήσεις που αναφέρθηκαν παραπάνω, μπορούμε να μάθουμε από απλές διαδικτυακές εφαρμογές 5G (Fettweis, 2014) ότι ο ασύρματος δικτυωμένος έλεγχος ρομποτικών αντικειμένων (π.χ. αυτοματοποιημένη οδήγηση ή εργοστασιακή εφοδιαστική) είναι μια νέα συναρπαστική εφαρμογή για κυτταρική τεχνολογία, αλλά αυτό δημιουργεί επίσης νέες προκλήσεις. Κατά την ανάλυση της κίνησης δικτύου που δημιουργείται από αυτές τις εφαρμογές, πολλά κινητά αντικείμενα πρέπει να μοιράζονται πληροφορίες αισθητήρα καθώς και πληροφορίες ελέγχου, οι οποίες υπερφορτώνουν ένα κεντρικό σύστημα ελέγχου. Αντ' αυτού, τα κατανομημένα συστήματα ελέγχου που χρησιμοποιούν AI γίνονται το επίκεντρο της έρευνας και της ανάπτυξης. Συγκεκριμένα, η ομοσπονδιακή μάθηση δείχνει να είναι μια πολλά υποσχόμενη προσέγγιση, όπου οι αλγόριθμοι συσχέτισης συνόλων δεδομένων κατανομούνται σε κινητά ρομποτικά αντικείμενα και η συγκεντρωτική μάθηση συμβαίνει πάνω από το σύννεφο. Είναι ενδιαφέρον ότι αυτό δημιουργεί μια εντελώς νέα κατηγορία κυκλοφορίας δικτύου, με μεγάλο εύρος ζώνης και ποικίλες απαιτήσεις καθυστέρησης. Είναι πολύ πιθανό να υποθέσουμε ότι αυτές και ισοδύναμες εφαρμογές AI όχι μόνο θα ξεπεράσουν, αλλά θα κυριαρχήσουν στις απαιτήσεις κυκλοφορίας δικτύου του 6G. Αυτό είναι άθικτο έδαφος, γεγονός που το καθιστά συναρπαστικό και πολύ δύσκολο ταυτόχρονα.

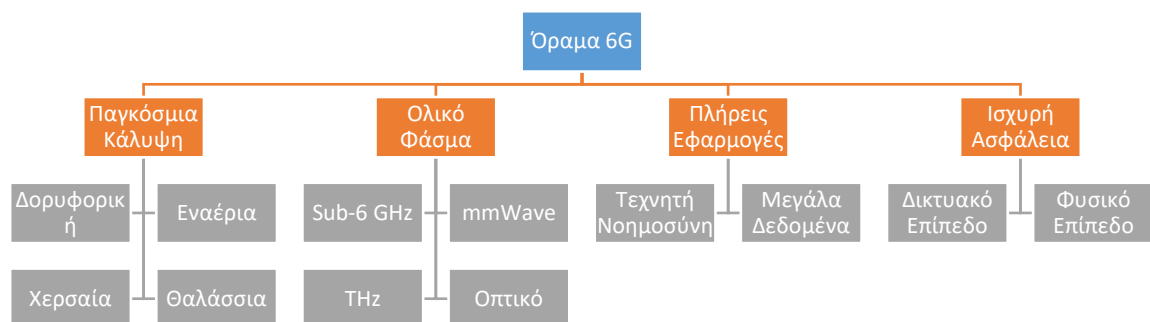
Σε σύγκριση με το δίκτυο 5G, τα δίκτυα ασύρματης επικοινωνίας 6G αναμένεται να παρέχουν πολύ υψηλότερη απόδοση φάσματος / ενέργειας / κόστους, υψηλότερο ρυθμό δεδομένων (Tbps), 10 φορές χαμηλότερη καθυστέρηση, 100 φορές υψηλότερη πυκνότητα σύνδεσης, περισσότερη ευφυΐα για πλήρη αυτοματοποίηση, ακρίβεια γεωγραφικής θέσης εκατοστόμετρου, κάλυψη σχεδόν 100% και συγχρονισμός δευτερολέπτου. Οι νέες τεχνολογίες διασύνδεσης και μετάδοσης αέρα είναι απαραίτητες για την επίτευξη υψηλής απόδοσης φάσματος και ενεργειακής απόδοσης, συμπεριλαμβανομένων νέων κυματομορφών, προσεγγίσεων πολλαπλής πρόσβασης, μεθόδων κωδικοποίησης καναλιών, τεχνολογιών πολλαπλών κεραιών και κατάλληλου συνδυασμού όλων αυτών των τεχνικών ποικιλομορφίας. Εν τω μεταξύ, απαιτούνται νέες αρχιτεκτονικές δικτύου, για παράδειγμα, εικονικοποίηση λειτουργιών δικτύου / δικτύου που ορίζεται από λογισμικό (“software defined network/network functions virtualization” - SDN / NFV), δυναμική κοπή δικτύου, αρχιτεκτονική βάσει υπηρεσιών (SBA), αρχιτεκτονική γνωστικών υπηρεσιών (“cognitive service architecture”- CSA) και χωρίς κελιά (“cell-free” - CF) αρχιτεκτονικές.

Ωστόσο, η διαδικασία μετατροπής των πάντων σε software (“softwarization” You et al, 2021), έχει κόστος, καθώς μπορούμε να μάθουμε από την ανάπτυξη 5G. Η χρήση εμπορικών διακομιστών off-the-shelf (COTS) έναντι τσιπ συγκεκριμένων τομέων σε εικονικό δίκτυο ραδιοπρόσβασης (RAN) συνεπάγεται μεγάλη αύξηση της κατανάλωσης ενέργειας, αντισταθμίζοντας μέτρα για τη βελτίωση της ενεργειακής απόδοσης. Αυτό οδηγεί στο τρέχον γεγονός ότι τα δίκτυα 5G καταναλώνουν περισσότερη ισχύ από τα δίκτυα 4G, αλλά φυσικά με την παράδοση υψηλότερου εύρους ζώνης. Αντίθετα, πρέπει να παρέχουμε δίκτυα που κατά τη στιγμή της εισαγωγής τους δεν υπερβαίνουν τις ανάγκες ισχύος της προηγούμενης γενιάς. Για το 6G, επομένως, θα απαιτήσουμε ένα νέο υπολογιστικό παράδειγμα για να υποστηρίξουμε όλα τα οφέλη της μαλακοποίησης χωρίς να επιβαρυνθούμε με το κόστος της κατανάλωσης ενέργειας.

Οι τεχνολογίες υπολογιστών όπως ο υπολογισμός νέφους, ομίχλη και ο υπολογιστής αιχμής είναι σημαντικές για την ανθεκτικότητα του δικτύου, τον κατανεμημένο υπολογισμό και την επεξεργασία, καθώς και τον χαμηλότερο λανθάνοντα χρόνο και συγχρονισμό χρόνου. Προκειμένου να επιλυθούν οι περιορισμοί του 5G, συμπεριλαμβανομένου του μειονεκτήματος του σύντομου πακέτου, παρέχεται η υψηλή αξιοπιστία υπηρεσιών χαμηλού λανθάνοντος χρόνου με υψηλούς ρυθμούς δεδομένων και η κάλυψη συστήματος και Διαδίκτυο όλων (IoE) (Saad et al, 2020), Για να

ικανοποιηθούν οι απαιτήσεις των κινητών επικοινωνιών το 2030 και μετά (Zong et al, 2019), το δίκτυο 6G θα πρέπει να μετατραπεί σε ανθρωποκεντρικό, αντί για κεντρικό σε υπολογιστή, κεντρικό για εφαρμογές ή κεντρικό με βάση τα δεδομένα, ως το όραμα (Dang et al, 2020). Για την εκπλήρωση αυτών των απαιτήσεων, τα δίκτυα ασύρματης επικοινωνίας 6G θα έχουν νέες αλλαγές παραδειγμάτων. Το όραμά για το δίκτυο 6G απεικονίζεται στο παρακάτω Σχήμα.

Εικόνα 1 Ένα όραμα για ασύρματα δίκτυα επικοινωνίας 6G



(You et al, 2021)

Πρώτα απ' όλα, τα δίκτυα ασύρματης επικοινωνίας 6G θα πρέπει να είναι ολοκληρωμένα δίκτυα διαστήματος-αέρα-εδάφους-θάλασσας για να παρέχουν πλήρη παγκόσμια κάλυψη. Η δορυφορική επικοινωνία, η επικοινωνία UAV και η θαλάσσια επικοινωνία θα επεκτείνουν σε μεγάλο βαθμό το εύρος κάλυψης των ασύρματων δικτύων επικοινωνίας. Για την παροχή υψηλότερου ρυθμού δεδομένων, όλα τα φάσματα θα διερευνηθούν πλήρως, συμπεριλαμβανομένων των ζωνών sub-6 GHz, mmWave, THz και οπτικών συχνοτήτων. Για να ενεργοποιηθούν οι πλήρεις εφαρμογές, οι τεχνολογίες AI και ML θα συνδυάζονται αποτελεσματικά με δίκτυα ασύρματης επικοινωνίας 6G για καλύτερη διαχείριση και αυτοματισμό δικτύου. Επιπλέον, η τεχνολογία AI μπορεί να επιτρέψει τη δυναμική ενορχήστρωση πόρων δικτύωσης, προσωρινής αποθήκευσης και υπολογιστών για τη βελτίωση της απόδοσης των δικτύων επόμενης γενιάς. Η τελευταία αλλά όχι η ελάχιστη τάση είναι η ισχυρή ή ενδογενής ασφάλεια δικτύου τόσο για το φυσικό επίπεδο όσο και για το επίπεδο δικτύου κατά την ανάπτυξή του. Οι κλάδοι της βιομηχανίας, όπως το cloud VR, ο αυτοματισμός του διαδικτύου των πραγμάτων (IoT), το κυψελοειδές όχημα για τα πάντα (C-V2X), το ψηφιακό δίκτυο περιοχής δύο αμαξωμάτων και ο ενεργειακά αποδοτικός έλεγχος ασύρματου δικτύου και τα ενοποιημένα συστήματα μάθησης θα ενισχύσουν σε μεγάλο βαθμό τις εξελίξεις του 6G ασύρματα δίκτυα επικοινωνίας (Letaief et al, 2019).

Μια επισκόπηση των ασύρματων δικτύων 6G φαίνεται στο Σχήμα 2, όπου δίνονται οι μετρήσεις απόδοσης, τα σενάρια εφαρμογών, οι τεχνολογίες ενεργοποίησης, οι νέες αλλαγές παραδείγματος και οι κλάδοι της βιομηχανίας.

Εικόνα 2 Μια επισκόπηση των δικτύων ασύρματης επικοινωνίας 6G



(Kato et al, 2020)

1.1 Σκοπός της Εργασίας

Σε αυτή την εργασία, γίνεται μια ολοκληρωμένη έρευνα σχετικά με τα δίκτυα με τεχνολογία AI που εξελίσσονται προς το 6G. Παρουσιάζεται το όραμα του συστήματος 6G με δυνατότητα AI, οι κινητήριες δυνάμεις της εισαγωγής του AI και του ML σε 6G δίκτυα καθώς και οι τελευταίες τεχνολογίες στη μηχανική μάθηση. Στη συνέχεια, η εφαρμογή τεχνικών μηχανικής εκμάθησης σε μεγάλα ζητήματα δικτύου 6G, όπως Advanced Wireless Interface, έξυπνος έλεγχος κυκλοφορίας, προστασία ασφάλειας, διαχείριση και ενορχήστρωση και η βελτιστοποίηση δικτύου συζητείται εκτενώς. Επιπλέον, εξετάζεται η τελευταία πρόοδος των μεγάλων πρωτοβουλιών τυποποίησης και των ερευνητικών προγραμμάτων της βιομηχανίας σχετικά με την εφαρμογή μηχανικής μάθησης σε δίκτυα κινητής τηλεφωνίας που εξελίσσονται προς το 6G. Τέλος, εντοπίζονται σημαντικά ανοιχτά ζητήματα ώστε να μπορέσουν να υπάρξουν περαιτέρω μελέτες προς ένα έξυπνο, αποτελεσματικό και ασφαλές σύστημα 6G.

2 Θεωρητικό Πλαίσιο

2.1 Τεχνητή Νοημοσύνη

Η τεχνητή νοημοσύνη (AI) είναι ένας κλάδος της επιστήμης των υπολογιστών. Περιλαμβάνει την ανάπτυξη προγραμμάτων υπολογιστών για την ολοκλήρωση εργασιών που διαφορετικά θα απαιτούσαν ανθρώπινη νοημοσύνη. Οι αλγόριθμοι AI μπορούν να αντιμετωπίσουν τη μάθηση, την αντίληψη, την επίλυση προβλημάτων, την κατανόηση της γλώσσας και/ή τη λογική συλλογιστική (Tang et al, 2019).

Το AI χρησιμοποιείται με πολλούς τρόπους στον σύγχρονο κόσμο, από προσωπικούς βοηθούς έως αυτο-οδήγηση αυτοκινήτου. Η τεχνητή νοημοσύνη εξελίσσεται ραγδαία.

Χαρακτηριστικά γνωρίσματα της τεχνητής νοημοσύνης είναι τα ακόλουθα:

- **Η δυνατότητα πρόβλεψης και προσαρμογής**, το AI χρησιμοποιεί αλγόριθμους που ανακαλύπτουν μοτίβα από τεράστιες ποσότητες πληροφοριών.
- **Λαμβάνει αποφάσεις από μόνη της**, η τεχνητή νοημοσύνη είναι ικανή να αυξήσει την ανθρώπινη νοημοσύνη, να προσφέρει πληροφορίες και να βελτιώσει την παραγωγικότητα.
- **Συνεχής μάθηση**, το AI χρησιμοποιεί αλγόριθμους για την κατασκευή αναλυτικών μοντέλων. Από αυτούς τους αλγόριθμους, η τεχνολογία AI θα ανακαλύψει πώς να εκτελεί εργασίες μέσω αναρίθμητων δοκιμών και σφαλμάτων.
- **Η τεχνητή νοημοσύνη είναι προσανατολισμένη προς τα εμπρός**, το AI είναι ένα εργαλείο που επιτρέπει στους ανθρώπους να επανεξετάσουν τον τρόπο με τον οποίο αναλύουν δεδομένα και ενσωματώνουν πληροφορίες και, στη συνέχεια, χρησιμοποιούν αυτές τις πληροφορίες για τη λήψη καλύτερων αποφάσεων.
- **Το AI είναι ικανό κίνησης και αντίληψης** (Sun et al, 2020).

2.1.1 Τύπος 1

Η τεχνητή νοημοσύνη σήμερα είναι γνωστή ως στενή τεχνητή νοημοσύνη (ή αδύναμη τεχνητή νοημοσύνη), είναι μη συναισθηματική ευφυΐα μηχανής, τυπικά σχεδιασμένη για να εκτελεί μια στενή εργασία (π.χ. μόνο αναγνώριση προσώπου ή μόνο αναζητήσεις στο Διαδίκτυο ή μόνο οδήγηση αυτοκινήτου) (Hoyidis et al, 2020).

Ωστόσο, ο μακροπρόθεσμος στόχος πολλών ερευνητών είναι να δημιουργήσουν μια τεχνητή γενική νοημοσύνη (Artificial General Intelligence - AGI ή ισχυρή τεχνητή νοημοσύνη) που είναι μια μηχανή με την ικανότητα να εφαρμόζει νοημοσύνη σε οποιοδήποτε πρόβλημα, και όχι μόνο σε ένα συγκεκριμένο πρόβλημα, που συνήθως σημαίνει τουλάχιστον όσο έξυπνη όσο ένας τυπικός άνθρωπος (Nawaz et al, 2019).

Ενώ η στενή τεχνητή νοημοσύνη μπορεί να ξεπεράσει τους ανθρώπους ανεξάρτητα από το συγκεκριμένο έργο της, όπως στο σκάκι ή η επίλυση εξισώσεων, η AGI θα ξεπέρασε τους ανθρώπους σχεδόν σε κάθε γνωστική εργασία.

Ο απώτερος υποθετικός στόχος είναι η επίτευξη της υπερ-ευφυΐας (Achieving Super intelligence ASI), η οποία ξεπερνά κατά πολύ αυτή του λαμπρότερου και πιο ταλαντούχου ανθρώπινου νου. Λόγω της αναδρομικής αυτο-βελτίωσης, η υπερ-ευφυΐα αναμένεται να είναι ένα γρήγορο αποτέλεσμα της δημιουργίας τεχνητής γενικής νοημοσύνης (Kaur et al, 2021).

2.1.2 Τύπος 2 (με βάση λειτουργίες)

2.1.2.1 Αμιγώς αντιδραστικό

Τα αντιδραστικά μηχανήματα είναι βασικά από την άποψη ότι δεν αποθηκεύουν «αναμνήσεις» ή χρησιμοποιούν προηγούμενες εμπειρίες για τον προσδιορισμό μελλοντικών ενεργειών. Απλώς αντιλαμβάνονται τον κόσμο και αντιδρούν σε αυτόν. Το Deep Blue της IBM, που νίκησε τον grandmaster του σκακιού Kasparov, είναι μια αντιδραστική μηχανή που βλέπει τα κομμάτια σε μια σκακιέρα και αντιδρά σε αυτά. Δεν μπορεί να ανατρέξει σε καμία από τις προηγούμενες εμπειρίες του και δεν μπορεί να βελτιωθεί με την εξάσκηση (Ali et al, 2020).

2.1.2.2 Περιορισμένης Μνήμης

Τα μηχανήματα περιορισμένης μνήμης μπορούν να διατηρούν δεδομένα για μικρό χρονικό διάστημα. Ενώ μπορούν να χρησιμοποιήσουν αυτά τα δεδομένα για ένα συγκεκριμένο χρονικό διάστημα, δεν μπορούν να τα προσθέσουν σε μια βιβλιοθήκη των εμπειριών τους. Πολλά αυτοκινούμενα αυτοκίνητα χρησιμοποιούν τεχνολογία περιορισμένης μνήμης: αποθηκεύουν δεδομένα όπως την πρόσφατη ταχύτητα των κοντινών αυτοκινήτων, την απόσταση τέτοιων αυτοκινήτων, το όριο ταχύτητας και άλλες πληροφορίες που μπορούν να τα βοηθήσουν να περιηγηθούν στους δρόμους (Loven et al, 2019).

2.1.2.3 Θεωρία του Νου

Η ψυχολογία λέει ότι οι άνθρωποι έχουν σκέψεις, συναισθήματα, αναμνήσεις και νοητικά πρότυπα που καθοδηγούν τη συμπεριφορά τους. Οι ερευνητές της Θεωρίας του Νου ελπίζουν να χτίσουν υπολογιστές που μιμούνται τα πνευματικά μοντέλα των ανθρώπων, σχηματίζοντας παραστάσεις για τον κόσμο και για άλλους παράγοντες και οντότητες σε αυτόν. Ένας στόχος αυτών των ερευνητών είναι να δημιουργήσουν υπολογιστές που σχετίζονται με τον άνθρωπο και αντιλαμβάνονται την ανθρώπινη νοημοσύνη και πώς τα συναισθήματα των ανθρώπων επηρεάζονται από γεγονότα και το περιβάλλον. Ενώ πολλοί υπολογιστές χρησιμοποιούν μοντέλα, ένας υπολογιστής με «μυαλό» δεν υπάρχει ακόμη (Zhang et al, 2019).

2.1.2.4 Αυτογνωσία

Τα μηχανήματα με αυτογνωσία είναι το αντικείμενο της επιστημονικής φαντασίας, αν και πολλοί λάτρεις της τεχνητής νοημοσύνης πιστεύουν ότι είναι ο απώτερος στόχος της ανάπτυξης της τεχνητής νοημοσύνης. Ακόμα κι αν ένα μηχάνημα μπορεί να λειτουργήσει όπως ένα άτομο, για παράδειγμα διατηρώντας τον εαυτό του, προβλέποντας τις δικές του ανάγκες και απαιτήσεις και να σχετίζεται με άλλους ως ίσος, το ερώτημα αν μια μηχανή μπορεί να έχει πραγματικά αυτογνωσία ή «συνείδηση», είναι καλύτερα να μείνει για τους φιλόσοφους (Du et al, 2020).

2.2 Μηχανική Εκμάθηση

Ο στόχος της Μηχανικής Μάθησης είναι η κατασκευή προγραμμάτων υπολογιστών που μπορούν να μάθουν από δεδομένα. Το επαγωγικό συμπέρασμα της μηχανικής μάθησης, δηλαδή οι γενικεύσεις από ένα σύνολο παρατηρημένων περιπτώσεων, μπορεί να αντιπαραβληθεί με τις πρώιμες προσεγγίσεις Τεχνητής Νοημοσύνης που ασχολήθηκαν κυρίως με την αφαιρετική συναγωγή, δηλαδή, η παραγωγή των θεωρημάτων από αξιώματα. Αν και η μηχανική μάθηση θεωρείται υποπεδίο της τεχνητής νοημοσύνης, τέμνεται επίσης με πολλούς άλλους επιστημονικούς κλάδους όπως στατιστική, γνωστική επιστήμη και θεωρία πληροφοριών. Μια περιοχή, που σχετίζεται στενά με μηχανική μάθηση είναι η εξόρυξη δεδομένων που ασχολείται με την ανακάλυψη νέων και ενδιαφέρων προτύπων από μεγάλα σύνολα δεδομένων. Παρόλο που η μηχανική μάθηση και η εξόρυξη δεδομένων χρησιμοποιούνται συχνά εναλλακτικά, μπορεί κανείς να δηλώσει ότι η μηχανική μάθηση επικεντρώνεται περισσότερο στην προσαρμοστική συμπεριφορά και τη λειτουργική χρήση, ενώ η

εξόρυξη δεδομένων επικεντρώνεται στο χειρισμό μεγάλων ποσοτήτων δεδομένων και στην ανακάλυψη προηγουμένως άγνωστων προτύπων (έμμεσες γνώσεις, κανονικότητες) στα δεδομένα. Το μεγαλύτερο μέρος αυτού του κεφαλαίου συζητά τη μηχανική μάθηση στο πλαίσιο ενός επίσημου συστήματος AI, αν και όταν είναι κατάλληλο, όπως στη συζήτηση των γραφικών μοντέλων, υιοθετείται μια πιο στατιστική προσέγγιση. Οι προσεγγίσεις μηχανικής μάθησης μπορούν να διακριθούν ως προς την αναπαράσταση και την προσαρμογή. Ένα σύστημα μηχανικής μάθησης πρέπει να αποθηκεύει τις πληροφορίες που έχει μάθει σε κάποια δομή αναπαράστασης της γνώσης που ονομάζεται (επαγωγική) υπόθεση και έχει συνήθως τη μορφή ενός μοντέλου. Ακολουθώντας την αρχή του ξυραφιού του Ockham, η υπόθεση θα πρέπει να γενικεύσει τα δεδομένα εκπαίδευσης δίνοντας προτεραιότητα στην απλούστερη υπόθεση. Για να επιτευχθεί έγκυρη γενίκευση, η υπόθεση πρέπει να είναι απλούστερη από τα ίδια τα δεδομένα. Ένας αλγόριθμος εκμάθησης καθορίζει τον τρόπο ενημέρωσης της υπόθεσης που έχει μάθει με νέα εμπειρία (δηλαδή δεδομένα εκπαίδευσης) έτσι ώστε να βελτιστοποιείται το μέτρο απόδοσης σε σχέση με την εργασία (Torkos et al, 2020).

Τα καθήκοντα της ταξινόμησης και της παλινδρόμησης ασχολούνται με την πρόβλεψη της τιμής ενός πεδίου (ο στόχος) με βάση τις τιμές των άλλων πεδίων (χαρακτηριστικά). Εάν ο στόχος είναι διακριτός (π.χ. ονομαστικός ή κανονικός), τότε η δεδομένη εργασία ονομάζεται ταξινόμηση. Εάν ο στόχος είναι συνεχής, η εργασία ονομάζεται παλινδρόμηση. Η ταξινόμηση ή η παλινδρόμηση είναι συνήθως εποπτευόμενες διαδικασίες: με βάση ένα προηγουμένως σωστά επισημασμένο σύνολο εκπαιδευτικών περιπτώσεων, το μοντέλο μαθαίνει να επισημαίνει σωστά νέες αόρατες εμφανίσεις (Cousik et al, 2019).

Ένας συσχετισμός περιγράφει μια σχέση μεταξύ αντικειμένων, ή μετρημένων ποσοτήτων, που είναι το αποτέλεσμα κάποιας αλληλεπίδρασης ή εξάρτησης μεταξύ των αντικειμένων. Συνήθως, οι συσχετισμοί έχουν τη μορφή κανόνων συσχέτισης ή συνόλων συχνών στοιχείων. Το κίνητρο για αυτόν τον τύπο εργασίας έχει παρασχεθεί με ανάλυση καλαθιού αγοράς όπου μελετώνται οι μέθοδοι εύρεσης συσχετίσεων μεταξύ προϊόντων που αγοράζονται από πελάτες. Για παράδειγμα, οι πελάτες που αγοράζουν X (π.χ. μύρα) συνήθως αγοράζουν επίσης Y (π.χ. σνακ). Τότε, αν ένας πελάτης που αγοράζει X αλλά δεν αγοράζει Y, ενδέχεται να στοχευθεί μέσω cross-selling ως δυνητικός πελάτης για το Y. Ένα σύνολο αντικειμένων καλείται συχνό εάν εμφανίζεται σε τουλάχιστον ένα δεδομένο ποσοστό (ονομάζεται υποστήριξη) όλων

των συναλλαγών. Τα συχνά σύνολα αντικειμένων είναι συχνά η προϋπόθεση για την εκμάθηση κανόνων σύνδεσης (Catak et al, 2021).

Η ομαδοποίηση είναι μια εργασία χωρίς επίβλεψη, της οποίας στόχος είναι η ομαδοποίηση ενός συνόλου αντικειμένων σε κλάσεις παρόμοιων αντικειμένων. Ένα σύμπλεγμα είναι μια συλλογή αντικειμένων που είναι παρόμοια μεταξύ τους εντός του ίδιου συμπλέγματος και ανόμοια με τα αντικείμενα σε άλλες ομάδες. Επομένως, μια σημαντική έννοια στην ομαδοποίηση (επίσης γνωστή ως ανάλυση συστάδων στα στατιστικά στοιχεία) είναι η έννοια της ομοιότητας (ή της απόστασης). Στην εννοιολογική ομαδοποίηση, εξάγεται μια συμβολική αναπαράσταση κάθε συστάδας και μπορεί να θεωρηθεί ότι κάθε συστάδα είναι μια έννοια, που σχετίζεται στενά με μια τάξη στην ταξινόμηση (Rodrigues et al, 2019).

Μερικά παραδείγματα άλλων καθηκόντων μηχανικής μάθησης είναι: μάθηση ενίσχυσης, εκμάθηση κατάταξης και δομημένη πρόβλεψη. Το έργο μάθησης ενίσχυσης αποτελείται από την εκμάθηση στρατηγικών διαδοχικού ελέγχου. Ασχολείται με καταστάσεις, όπου η έξοδος του συστήματος είναι μια ακολουθία ενεργειών που εκτελούνται για την επίτευξη κάποιου στόχου. Ένα παράδειγμα μπορεί να είναι το παιχνίδι, όπου η πλήρης ακολουθία κινήσεων είναι σημαντική, και όχι μία κίνηση. Η εκμάθηση κατάταξης είναι ένας τύπος (ημι-) εποπτευόμενου μαθησιακού προβλήματος όπου ο στόχος είναι μια αυτόματη κατασκευή ενός μοντέλου κατάταξης από δεδομένα εκπαίδευσης, π.χ. η κατανόηση της σημασίας των επιστρεφόμενων ιστοσελίδων σε μια εφαρμογή αναζήτησης. Η δομημένη πρόβλεψη ασχολείται με προβλήματα πρόβλεψης στα οποία το αποτέλεσμα είναι μια σύνθετη δομή. Τέτοια προβλήματα προκύπτουν σε κλάδους όπως η υπολογιστική γλωσσολογία, π.χ. στη φυσική ανάλυση γλώσσας, ομιλία, όραση και βιολογία (Xiao et al, 2020).

Οι υποθέσεις μηχανικής εκμάθησης μπορεί να έρχονται σε μια ποικιλία μορφών αναπαράστασης γνώσεων, όπως εξισώσεις, δέντρα αποφάσεων, κανόνες, αποστάσεις και χωρίσματα, πιθανοτικά και γραφικά μοντέλα. Κλασικά, γίνεται διαχωρισμός μεταξύ συμβολικών και υπο-συμβολικών μορφών αναπαράστασης της γνώσης. Η πρώτη κατηγορία αποτελείται από συστήματα αναπαράστασης στα οποία τα ατομικά δομικά στοιχεία είναι επίσημες συμβολικές αναπαραστάσεις, συχνά εύκολα αναγνώσιμες από τον άνθρωπο. Τέτοια συστήματα αναπαράστασης έχουν σύνταξη σύνταξης και σημασιολογίας, και στα συστατικά τους μπορεί να δοθεί ερμηνεία. Το σύστημα μπορεί, για παράδειγμα, να αποτελείται από ένα σύνολο κανόνων. Ένα καλό παράδειγμα ενός συμβολικού συστήματος είναι μια ερμηνευμένη λογική θεωρία. Με

τη σειρά τους, τα συστατικά ενός υπο-συμβολικού συστήματος αναπαράστασης δεν έχουν σαφή ερμηνεία και δεν αποτελούν επίσημες αναπαραστάσεις από μόνα τους. Η γνώση σε αυτήν την προσέγγιση αντιπροσωπεύεται ως αριθμητικά μοτίβα που καθορίζουν τον υπολογισμό μιας εξόδου όταν παρουσιάζεται μια δεδομένη είσοδος. Καλά παραδείγματα υπο-συμβολικών συστημάτων είναι τα νευρωνικά δίκτυα, όπου τα σχέδια αντιπροσωπεύονται με τη μορφή διασυνδεδεμένων ομάδων απλών τεχνητών νευρώνων (Dang et al, 2020).

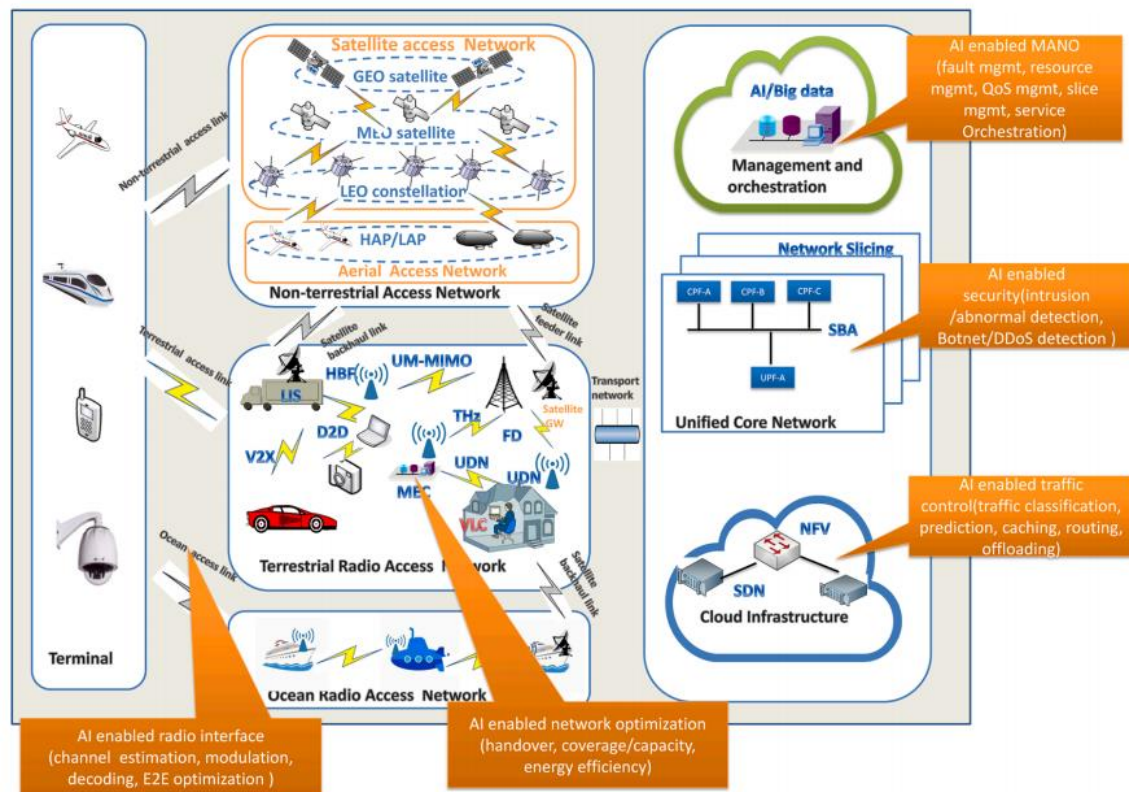
3 Δίκτυα 6G με Τεχνητή Νοημοσύνη

3.1 Το Πλαίσιο των Συστημάτων 6G

Το πρότυπο 5G φάσης 1 που ορίστηκε από το 3GPP R15 σταμάτησε τον Ιούνιο του 2018. Οι προδιαγραφές φάσης 2 του 5G που επικεντρώθηκαν στις μαζικές επικοινωνίες τύπου μηχανής (Massive Machine-Type Communications - mMTC) και οι εξαιρετικά αξιόπιστες επικοινωνίες χαμηλού λανθάνοντος χρόνου (Ultra-Reliable Low Latency Communications - URLLC) ολοκληρώθηκαν το 2020. Εν τω μεταξύ, αρκετοί κορυφαίοι παγκόσμιοι φορείς εκμετάλλευσης, όπως η NTT DOCOMO και η China Mobile, έχουν ξεκινήσει δοκιμές 5G από το 2019 και σχεδιάζουν να αναπτύξουν εμπορικά συστήματα 5G. Ιστορικά, μια νέα γενιά συστημάτων κινητής επικοινωνίας προκύπτει περίπου κάθε δεκαετία. Πρόσφατα, πολλοί ερευνητές από τη βιομηχανία και τον ακαδημαϊκό χώρο ξεκίνησαν τη μελέτη του 6G. Η ITU δημιούργησε μια νέα ομάδα εστίασης για το δίκτυο 2030 (FG NET-2030). Η πρώτη λευκή βίβλος 6G δημοσιεύθηκε τον Σεπτέμβριο του 2019. Στη συνέχεια, μια άλλη λευκή βίβλος 6G αφορούσε την ευφυΐα στην άκρη του 6G. Γενικά, ένα σύστημα νέας γενιάς εμφανίζεται ως αποτέλεσμα των μελλοντικών κοινωνικών απαιτήσεων και της ωριμότητας των νέων τεχνολογιών. Για να ανταποκριθεί στις ολοένα και πιο αυστηρές και ποικίλες απαιτήσεις απόδοσης, καθώς και στην πανταχού παρούσα κάλυψη δικτύου σε οτιδήποτε σε οποιοδήποτε μέρος και ανά πάσα στιγμή, η Εικ. 3 περιγράφει δίκτυα 6G για κινητά προσανατολισμένα σε ασύρματο-προς-οπτικά σε πολλαπλούς τομείς. Το σύστημα 6G ενσωματώνει ένα ευρύ φάσμα σεναρίων επικοινωνίας σε πολλούς τομείς, όπως διαστημικά δίκτυα που βασίζονται σε δορυφόρους, εναέρια δίκτυα που βασίζονται σε μη επανδρωμένα εναέρια οχήματα (Unmanned Aerial Vehicles - UAV), drone και πλατφόρμες μεγάλου υψομέτρου (High Altitude Platform - HAP), επίγεια δίκτυα που εξυπηρετούν εσωτερικούς και εξωτερικούς χρήστες, και συσκευές Internet of Things (IoT), ωκεάνια δίκτυα που βασίζονται σε πλοία και υποβρύχια. Τα ασύρματα δίκτυα πρόσβασης 6G θα γίνουν πραγματικότητα με αναδυόμενες τεχνολογίες όπως επικοινωνίες THz, επικοινωνίες ορατού φωτός (Visible-Light Communications - VLC), μεγάλη έξυπνη επιφάνεια (Large Intelligent Surface - LIS), εξαιρετικά μαζικό MIMO κ.α. Εκτός από τη συμβατική ικανότητα επικοινωνίας, το σύστημα 6G θα υποστηρίξει πολλές νέες δυνατότητες, όπως υπολογιστές, αποθήκευση περιεχομένου, και πιθανή ασύρματη μεταφορά ενέργειας. Τα ολοκληρωμένα δίκτυα 6G διαστήματος-εναέρια-χερσαία-ωκεανού θα πρέπει να υλοποιηθούν με μια ενοποιημένη

αρχιτεκτονική συστήματος που θα παρέχει πανταχού παρούσα και ευέλικτη κάλυψη, μαζική σύνδεση και υψηλή αξιοπιστία. Για την αποτελεσματική διαχείριση των σύνθετων συστημάτων 6G και την ενορχήστρωση διαφόρων πόρων σε διαφορετικούς τομείς με έναν αυτόματο τρόπο, οι έξυπνες λειτουργίες ελέγχου και διαχείρισης με δυνατότητα AI προβλέπονται να ενσωματωθούν στο κέντρο και στην άκρη της αρχιτεκτονικής του δικτύου για να επιτύχουν ένα ευέλικτο, προσαρμοστικό και έξυπνο σύστημα 6G (David et al, 2019).

Εικόνα 3 Ένα προβλεπόμενο πλαίσιο 6G.



(Viswanathan & Mogensen, 2020)

3.2 Νέες Υπηρεσίες και Απαιτήσεις

3.2.1 Ολογραφικές εφαρμογές

Με ταχεία ανάπτυξη σε νέες τεχνολογίες οθόνης, συσκευές ανίχνευσης και απεικόνισης, οι τεχνολογίες εικονικής πραγματικότητας (Virtual Reality - VR), επαυξημένης πραγματικότητας (Augmented Reality - AR) και μικτής πραγματικότητας (Mixed Reality - MR) εξελίσσονται προς την εκτεταμένη πραγματικότητα (Extended Reality - XR). Οι αναδυόμενες υπηρεσίες αλληλεπίδρασης που συνδυάζουν φορητές οθόνες και μηχανισμούς αλληλεπίδρασης μπορούν να δημιουργήσουν την αίσθηση πως το άτομο βρίσκεται αλλού. Οι ολογραφικές υπηρεσίες που ενσωματώνουν πολλαπλές ανθρώπινες αισθήσεις όπως γεύση, μυρωδιά, αφή, όραση και ακοή αναμένεται να προσφέρουν μια πραγματικά καθηλωτική εμπειρία. Οι εφαρμογές ολογραφίας θα απαιτούν ρυθμό δεδομένων της τάξης terabits ανά δευτερόλεπτο. Λόγω της απαίτησης πολύ χαμηλών καθυστερήσεων και υψηλού ρυθμού δεδομένων, το υπάρχον σύστημα 5G είναι ανίκανο να προσφέρει τέτοιες εμπειρίες συνδυάζοντας πολλαπλές αισθητηριακές εισόδους. Το XR απαιτεί συνδυασμό URLLC και

βελτιωμένης ευρυζωνικής σύνδεσης για κινητά (Enhanced Mobile Broadband - eMBB), εκτός από ενσωματωμένους αντιληπτικούς παράγοντες που πρέπει να υποστηρίζονται από το 6G (Saad et al, 2019).

3.2.2 Ευφυής κατασκευή

Η έξυπνη κατασκευή στοχεύει στη βελτίωση της αποδοτικότητας της παραγωγής και στη μείωση της ανθρώπινης παρέμβασης στις διαδικασίες κατασκευής, χρησιμοποιώντας αυτόματα συστήματα ελέγχου και αυτόνομη ρομποτική, σύστημα παράδοσης drone κ.λπ. Βασίζεται στο σύστημα ελέγχου σε πραγματικό χρόνο και ακριβές, το οποίο απαιτεί εξαιρετικά χαμηλό λανθάνοντα χρόνο της τάξης των 0,1-1ms και εξαιρετικά υψηλή αξιοπιστία της τάξης των 10^{-9} . Για τον ακριβή έλεγχο, ενδέχεται να είναι απαραίτητοι χάρτες υψηλής ευκρίνειας από κατανεμημένους αισθητήρες. Επιπλέον, ορισμένα βιομηχανικά συστήματα ελέγχου χαρακτηρίζονται από ισχυρό ντετερμινισμό, ο οποίος απαιτεί εξαιρετικά χαμηλή καθυστέρηση στην παράδοση μηνυμάτων ελέγχου. Συνολικά, τα ευφυή σενάρια κατασκευής θέτουν αυστηρές απαιτήσεις σε σχέση με το ρυθμό δεδομένων, την καθυστέρηση και την αξιοπιστία (Liu et al, 2020).

3.2.3 Έξυπνα περιβάλλοντα

Τα μελλοντικά έξυπνα και πράσινα περιβάλλοντα προβλέπονται για τη βελτίωση της ποιότητας της ζωής των ανθρώπων, παρέχοντας πολλαπλές νέες υπηρεσίες με επίκεντρο τον άνθρωπο. Οι διαδεδομένες νέες εφαρμογές μπορούν να συμβάλουν σε μεγάλο βαθμό σε έξυπνα περιβάλλοντα όπως έξυπνες μεταφορές, έξυπνα δίκτυα, έξυπνη γεωργία. Αυτές οι εφαρμογές απαιτούν διεισδυτική αντίχρεωση, εξόρυξη δεδομένων, έξυπνο έλεγχο και κατανεμημένο σύστημα ενεργοποίησης, που θέτουν αυστηρές απαιτήσεις. Μεγάλη ποσότητα δεδομένων που παράγονται από τις τεράστιες συσκευές IoT μπορεί να αναλυθεί αποτελεσματικά για να δημιουργηθεί στιγμιαία απόκριση μόνο εάν υπάρχουν υψηλής ποιότητας δίκτυα ασύρματης επικοινωνίας με ισχυρή υπολογιστική ικανότητα. Εν τω μεταξύ, η εκθετική επέκταση των συσκευών IoT απαιτεί σημαντική βελτίωση στους αριθμούς σύνδεσης και την κάλυψη του 6G (Jameel et al, 2020).

3.2.4 Αλληλεπιδράσεις εγκεφάλου-υπολογιστή

Οι τεχνολογίες αλληλεπίδρασης εγκεφάλου-υπολογιστή (Brain-Computer Interaction BCI) μπορούν να χρησιμοποιηθούν για τη δημιουργία μιας διαδρομής άμεσης επικοινωνίας μεταξύ του εγκεφάλου και των εξωτερικών συσκευών. Με βάση τις ασύρματες τεχνολογίες αλληλεπίδρασης εγκεφάλου-υπολογιστή, τα άτομα μπορούν να αλληλεπιδράσουν με περιβάλλοντα μέσω ενσωματωμένων ή εμφυτευμένων συσκευών, γεγονός που καθιστά δυνατή την αλληλεπίδραση των ανθρώπων με περιβάλλοντα μέσω μυαλού και χειρονομιών. Με την έλευση της αλληλεπίδρασης εγκεφάλου-υπολογιστή, νέα σενάρια, όπως ταινίες τις οποίες ελέγχουν πολλαπλοί εγκέφαλοι, νέες συσκευές που χρησιμοποιούνται στο σπίτι και ιατρικά συστήματα ενδέχεται να γίνουν πραγματικότητα στο πλαίσιο του 6G. Τέτοιες ενσυναισθητικές και απτικές επικοινωνίες αποτελούν σημαντικό τύπο περιπτώσεων χρήσης για το 6G. Σε αντίθεση με το XR, οι εφαρμογές που βασίζονται στην αλληλεπίδραση εγκεφάλου-υπολογιστή απαιτούν φυσικές αντιλήψεις και εγγυήσεις ποιότητας-φυσικής εμπειρίας εκτός από βασικές απαιτήσεις όπως εξαιρετικά χαμηλός λανθάνων χρόνος, υψηλός ρυθμός δεδομένων και υψηλή αξιοπιστία (Wilhelmi et al, 2021).

3.2.5 Επέκταση κάλυψης 3D

Με την επέκταση της περιοχής δραστηριότητας των ανθρώπων, θα χρειαστεί μεγαλύτερο τρισδιάστατο περιβάλλον επικοινωνίας (3D). Τα τρισδιάστατα δίκτυα που περιλαμβάνουν διαστημικά, εναέρια, επίγεια και ωκεάνια σημεία ασύρματης πρόσβασης και κινητές συσκευές αιχμής αναμένεται να παρέχουν οικονομικά αποδοτικές υπηρεσίες επικοινωνίας σε πολύ μεταβαλλόμενες απαιτήσεις σε χρόνο και χώρο, όπως σποραδικά γεγονότα ή καταστάσεις καταστροφών. Αν και η μη επίγεια ολοκλήρωση δικτύου στο 5G έχει μελετηθεί από, η τυπική και τεχνική υλοποίηση των δορυφορικών δικτύων και αυτή των επίγειων δικτύων εξακολουθούν να είναι ανεξάρτητα αντί να ενσωματώνονται. Η ικανότητα του συστήματος και η αποτελεσματικότητα των μη επίγειων 5G ενσωματωμένων δικτύων δεν μπορούν να ικανοποιήσουν την αυξανόμενη απαίτηση σε μια δεκαετία. Η ακραία τρισδιάστατη κάλυψη θέτει νέες προκλήσεις στον σχεδιασμό και τη βελτιστοποίηση του δικτύου, τη διαχείριση πόρων και τη δρομολόγηση λόγω της νέας διάστασης του υψομέτρου και των σχετικών βαθμών ελευθερίας (Khan et al, 2020).

3.3 Νέες Τεχνολογίες Πρόσβασης

3.3.1 *Επικοινωνία Terahertz*

Για την εκπλήρωση των απαιτήσεων ρυθμού δεδομένων από νέες υπηρεσίες όπως το XR, μπορεί να αξιοποιηθεί το άφθονο επαρκές φάσμα σε mmWave και THz band. Επομένως, τα δίκτυα 6G πρέπει να διερευνήσουν διάφορες τεχνολογίες ενεργοποίησης, όπως επικοινωνία THz και κελιά Tiny για την παροχή υπηρεσίας ρυθμού δεδομένων Tbps. Η κύρια πρόκληση της επικοινωνίας THz έγκειται στον χρησιμοποιήσιμο πομποδέκτη επειδή η παραγωγή σημάτων THz είναι πολύ υψηλή για συσκευές με βάση ηλεκτρονικά και πολύ χαμηλή για τις συσκευές που βασίζονται στη φωτονική. Λόγω της πρόκλησης του πομποδέκτη THz, η ζώνη THz είναι ένα από το λιγότερο εκμεταλλευόμενα φάσματα. Πρόσφατα, οι συσκευές με βάση το γραφένιο εμφανίστηκαν ως ένας πολλά υποσχόμενος πομποδέκτης για την παραγωγή σημάτων THz χάρη στα εξαιρετικά ηλεκτρο-οπτικά χαρακτηριστικά του γραφενίου. Δεδομένου ότι τα σήματα THz υποφέρουν από τη σοβαρή απώλεια διαδρομής ελεύθερου χώρου, η οποία περιλαμβάνει απώλεια εξάπλωσης και απώλεια μοριακής απορρόφησης οι ζώνες THz είναι πιο κατάλληλες για ασύρματες επικοινωνίες μικρής απόστασης, όπως ασύρματη ανάκτηση μικροσκοπικών κυττάρων. Για να ξεπεραστεί ο περιορισμός απόστασης, διάφορες πιθανές τεχνολογίες, όπως η εξαιρετικά μαζική MIMO (UM-MIMO) βρίσκονται υπό εκτεταμένη εξέταση. Η επικοινωνία THz θα ωριμάσει σταδιακά τα επόμενα χρόνια και θα διαδραματίσει σημαντικό ρόλο στο περδίο του 6G (Yang et al, 2020).

3.3.2 *Επικοινωνία ορατού φωτός*

Η επικοινωνία ορατού φωτός είναι μια άλλη πιθανή τεχνολογία που παρέχει τον ρυθμό δεδομένων Tbps χρησιμοποιώντας το ορατό φάσμα. Τα πλεονεκτήματα της περιλαμβάνουν άφθονο άδειο φάσμα, επαναχρησιμοποίηση πολύ υψηλού φάσματος και μηδενικές ηλεκτρομαγνητικές παρεμβολές. Χρησιμοποιώντας διόδους εκπομπής φωτός διαμορφωμένων δεδομένων (LED) ως πομπό και φωτοδιόδους ως δέκτη, η επικοινωνία ορατού φωτός είναι μια πολλά υποσχόμενη προσέγγιση για την παροχή εξαιρετικά υψηλών ρυθμών bit. Με την εισαγωγή νέων πηγών φωτός που βασίζονται σε μικρο-LED, η απόδοση της επικοινωνίας ορατού φωτός μπορεί να βελτιωθεί σημαντικά σε περίπου 10Gbps με ένα μόνο LED. Για να επιτευχθεί η απόδοση Tbps,

πρέπει να μελετηθεί περαιτέρω ο συνδυασμός πινάκων μικρο-LED και χωρικών πολυπλέξεων (Zhang et al, 2020).

3.3.3 Ολογραφική ραδιοσυχνότητα

Με την ταχεία ανάπτυξη προηγμένων τεχνολογιών κεραίας, όπως η μεταεπιφάνεια, οι αναδιαμορφώσιμες έξυπνες επιφάνειες (Reconfigurable Intelligent Surfaces - RIS), γνωστές και ως, μεγάλες έξυπνες επιφάνειες (Large Intelligent Surfaces - LIS) με βάση παθητικούς ανακλαστήρες και ελεγχόμενα στοιχεία προσελκύουν αυξανόμενη προσοχή τα τελευταία χρόνια. Σε αντίθεση με τις συμβατικές συστοιχίες κεραιών, το LIS μπορεί να διαπεράσει το όριο του μισού μήκους κύματος με χαμηλό κόστος και χαμηλή κατανάλωση ενέργειας μέσω διαστημικής συνεχούς οπής μετάδοσης / λήψης ραδιοσυχνότητας μέσω μιας έξυπνης επιφάνειας, η οποία αποτελείται από μεγάλο αριθμό παθητικών στοιχείων ανάκλασης με ελεγχόμενη φάση ή πλάτος. Με το χειρισμό του περιβάλλοντος διάδοσης ραδιοσυχνότητας σε ασύρματες επικοινωνίες 6G, η έξυπνη ραδιοσυχνότητα με βάση τα RIS μπορεί να καταπολεμήσει τις δυσμενείς συνθήκες διάδοσης. Με τη διευκόλυνση της LIS, η ολογραφική ραδιοσυχνότητα όπως το ολογραφικό MIMO, η ολογραφική δέσμη (HBF) βρίσκονται υπό ταχεία ανάπτυξη πρόσφατα. Το ολογραφικό MIMO είναι ικανό να διαμορφώνει ηλεκτρομαγνητικά κύματα στους επιθυμητούς στόχους μέσω μιας μεταβλητής ασύρματης επίπεδης δομής χαμηλού κόστους που περιλαμβάνει μεταλλικά σωματίδια υπο-μήκους κύματος. Το HBF είναι μια νέα τεχνική διαμόρφωσης δέσμης που χρησιμοποιεί κεραίες καθορισμένες από λογισμικό (Software-Defined Antennas - SDA) που χρησιμοποιούν αρχιτεκτονική δυναμικής διαμόρφωσης δέσμης, η οποία βασίζεται σε παθητικές κεραίες ηλεκτρονικής καθοδήγησης. Με ολογραφική καταγραφή και ανακατασκευή, το HBF μπορεί να παράγει ευέλικτα επιθυμητές δέσμες για να επιτύχει υψηλότερες χωρικές αναλύσεις από τις συμβατικές διαμορφώσεις δέσμης. Επιπλέον, η ολογραφική ραδιοσυχνότητα που βασίζεται στο LIS επιτρέπει τον έλεγχο κλειστού βρόχου του ηλεκτρομαγνητικού περιβάλλοντος μέσω φασματικής ολογραφίας και σύνθεσης χωρικών κυμάτων για τη βελτίωση της αποτελεσματικότητας του φάσματος και της χωρητικότητας του δικτύου. Εν τω μεταξύ, πολλά ανοιχτά ζητήματα, όπως η βέλτιστη ανάπτυξη παθητικών ανακλαστήρων και επιφανειακών επιφανειών, η παθητική μεταφορά πληροφοριών και η απόκτηση πληροφοριών κατάστασης καναλιού (Channel State Information - CSI), ο σχεδιασμός χαμηλής πολυπλοκότητας πρέπει να

αντιμετωπιστεί για να γίνει πραγματικότητα η ολογραφική ραδιοσυχνότητα (Catak et al, 2021).

3.3.4 Έξυπνη διεπαφή ραδιοσυχνότητας

Το αναδύομενο παράδειγμα μεταύλικού καθορισμένου από το λογισμικό και οι διαμορφώσιμες κεραιές διαρροής κυμάτων μπορούν να συμβάλουν σημαντικά στην έξυπνη διεπαφή αέρα 6G. Οι αναδιαμορφώσιμες κεραιές μπορούν να επιφέρουν σημαντικά κέρδη στο σύστημα προσαρμόζοντας δυναμικά τα μοτίβα δέσμης με βάση τις διαθέσιμες γνώσεις κατάστασης του καναλιού για κάθε κεραιάς. Οι μελλοντικές κεραιές και το μεταύλικό μπορούν να ελεγχθούν από απόσταση μέσω αλγορίθμων μηχανικής μάθησης με τη μορφή λογισμικού. Επιπλέον, η γνωστική ραδιοσυχνότητα που καθορίζεται από το λογισμικό μπορεί να παρέχει αξιόπιστες ασύρματες επικοινωνίες με αποτελεσματική χρήση των πόρων του φάσματος μέσω έξυπνων λειτουργιών με βάση τις γνώσεις που αντλούνται από τα γύρω περιβάλλοντα. Η μηχανική μάθηση μπορεί φυσικά να ενσωματωθεί σε όλες τις λειτουργίες γνωστικών ραδιοσυχνοτήτων, όπως ανίχνευση φάσματος, ανάλυση παρεμβολών και δυναμική διαχείριση πόρων φάσματος και έλεγχος ισχύος. Εκτός αυτού, οι τεχνικές μηχανικής μάθησης παρέχουν δυνατότητες για από κοινού βελτιστοποίηση της αλυσίδας λειτουργικότητας από άκρο σε άκρο του φυσικού στρώματος. Η εκμάθηση από άκρο σε άκρο έχει ως στόχο να αντιπροσωπεύει ολόκληρο το σύστημα επικοινωνίας, συμπεριλαμβανομένου του πομπού, του ασύρματου καναλιού και του δέκτη με ένα ενιαίο πλαίσιο εκμάθησης. Οι νέες τεχνικές καθιστούν δυνατή τη από κοινού βελτιστοποίηση πομπού και δεκτών με βάση την ανάκτηση πληροφοριών από άκρο σε άκρο. Η ενίσχυση της ευφυΐας των δικτύων ραδιοσυχνοτήτων από την μηχανική μάθηση για την επίτευξη αυτοδιαχείρισης, αυτοπροστασίας, αυτοθεραπείας και αυτοβελτιστοποίησης είναι προφανής για δίκτυα 6G (Bhat et al, 2021).

3.3.5 Αρχιτεκτονική δικτύου εγγενούς AI

Η αποθήκευση σε cloud, η οπτική αναπαράσταση, η εξάρτηση στο λογισμικό και ο τεμαχισμός του δικτύου (Network Slicing) εξακολουθούν να είναι σημαντικά χαρακτηριστικά της αρχιτεκτονικής 6G. Ωστόσο, η ευφυΐα θα είναι το βασικό χαρακτηριστικό για την ενεργοποίηση αυτόνομων δικτύων 6G. Ενεργοποιημένο από εγγενείς μηχανές AI, το σύστημα 6G μπορεί να ενορχηστρώσει αυτόματα τη δομή του

δικτύου και διάφορους πόρους όπως τμήματα δικτύου, υπολογιστές, προσωρινή αποθήκευση, ενέργεια, επικοινωνία για να ικανοποιήσει τις μεταβαλλόμενες απαιτήσεις. Η τοπολογία που βασίζεται σε AI και η διαχείριση πόρων είναι σημαντικές για την αποτελεσματική προσαρμογή της χρήσης διαφόρων πόρων με βάση μεταβαλλόμενα περιβάλλοντα και δυναμικές απαιτήσεις χρήστη. Λαμβάνοντας υπόψη την αυξανόμενη ικανότητα υπολογισμού και αποθήκευσης των συσκευών χρήστη, οι δυνατότητες που βασίζονται σε AI μπορούν να διανεμηθούν στην άκρη του δικτύου εκτός από την κεντρική ευφυΐα. Για να ξεπεραστεί ο περιορισμένος υπολογισμός, η αποθήκευση, η ισχύς των μεμονωμένων συσκευών, η αξιοποίηση των διεσπαρμένων πόρων υπολογιστών σε άκρες δικτύου και τελικές συσκευές μέσω υπολογιστών πολλαπλών σημείων πρόσβασης πρέπει να ληφθούν υπόψη στην αρχιτεκτονική 6G. Προβλέπεται ότι οι έξυπνες υπηρεσίες στο 6G θα εκτείνονται από κέντρα δεδομένων σε συσκευές στις άκρες του δικτύου και συσκευές χρήστη. Οι εφαρμογές που βασίζονται σε AI που εκτελούνται σε κινητές συσκευές ή σε άκρες δικτύου μπορούν να μάθουν και να προβλέψουν τη συμπεριφορά των χρηστών, τις περιβαλλοντικές συνθήκες και να λειτουργήσουν ως βοηθοί με γνώμονα το περιβάλλον σε κεντρικά συστήματα ελέγχου που βασίζονται σε AI. Εν τω μεταξύ, για να μετριαστούν οι ανησυχίες σχετικά με το απόρρητο των δεδομένων και την ασφάλεια της κατανεμημένης εκπαίδευσης σε συσκευές αιχμής, η ομοσπονδιακή μάθηση μπορεί να χρησιμοποιηθεί για να παρέχει μάθηση για τα τοπικά δεδομένα και για το παγκόσμιο μοντέλο μέσω της κοινής χρήσης των μοντέλων μάθησης από κατανεμημένες συσκευές (Guo 2020).

4 Παράγοντες που επιρρεάζουν την ανάπτυξη των Δικτύων 6G με Τεχνητή Νοημοσύνη

4.1 Προβλήματα μοντελοποίησης

Τα ακριβή μοντέλα καναλιών που αντιπροσωπεύουν πραγματικά περιβάλλοντα επικοινωνίας είναι σημαντικά για την απόδοση του ασύρματου συστήματος επικοινωνίας. Αν και τα υπάρχοντα μοντέλα καναλιών μπορούν να συλλάβουν τυπικά χαρακτηριστικά συμβατικών ασύρματων καναλιών, παρουσιάζουν περιορισμούς όσον αφορά τις ατέλειες και τις μη γραμμικότητες σε ορισμένα σύνθετα σενάρια. Για παράδειγμα, ο αυξανόμενος αριθμός κεραιών σε μαζική επικοινωνία MIMO έχει αλλάξει τις ιδιότητες του καναλιού, γεγονός που καθιστά άγνωστη την ακριβή μοντελοποίηση καναλιών. Επιπλέον, για αναμενόμενα σενάρια 6G, όπως μοριακές ή υποβρύχιες ακουστικές επικοινωνίες, είναι πολύ δύσκολο να χαρακτηριστούν τα κανάλια με άκαμπτα μαθηματικά μοντέλα. Ως εκ τούτου, είναι καιρός να εξερευνηθούν νέες προσεγγίσεις για το σχεδιασμό ενός συστήματος επικοινωνίας χωρίς σαφώς καθορισμένα μοντέλα καναλιών. Για το σκοπό αυτό, το μοντέλο βάσει δεδομένων δεν χρειάζεται ένα ακριβές μοντέλο για την επίλυση του προβλήματος, επειδή η λύση μπορεί να προέλθει απευθείας από τα δεδομένα που δημιουργούνται από τα δίκτυα. Αξιοποιώντας το μοντέλο που βασίζεται σε δεδομένα, η μπορεί να βελτιστοποιηθεί η απόδοση των ραδιοζεύξεων χρησιμοποιώντας μεγάλο σύνολο δεδομένων εκπαίδευσης χωρίς μαθηματικά ανιχνεύσιμο μοντέλο καναλιού. Επιπλέον, καθιστά δυνατή την εκμάθηση μοντέλων αναδύομενων καναλιών και την προσαρμογή στις νέες συνθήκες καναλιού με μεταγενέστερη εκπαίδευση (Lu & Ning, 2020).

4.2 Αποτελεσματική και γρήγορη επεξεργασία σήματος

Η επικοινωνία THz είναι πολύτιμη για το 6G για την εκπλήρωση των εξαιρετικά ευρυζωνικών εφαρμογών σε πραγματικό χρόνο, όπως επεκταμένη πραγματικότητα και απομακρυσμένων ολογραφικών επικοινωνιών για χρήστες κινητών. Η επεξεργασία σημάτων μεγάλης κλίμακας σε πραγματικό χρόνο είναι απαραίτητη για μελλοντικά προηγμένα συστήματα 6G. Δυστυχώς, οι συμβατικές επαναληπτικές προσεγγίσεις ανοικοδόμησης, όπως αλγόριθμοι για την ανίχνευση δεδομένων του MIMO οδηγούν σε υπολογιστική συμφόρηση για συστήματα σε πραγματικό χρόνο. Αντίθετα, τα νευρικά δίκτυα μπορούν να υλοποιηθούν με παράλληλους σε ταυτόχρονες

αρχιτεκτονικές και τύπους δεδομένων χαμηλής ακρίβειας. Έχει αποδειχθεί ότι οι αλγόριθμοι σε αυτήν τη μορφή θα μπορούσαν να εκτελεστούν γρηγορότερα και με χαμηλότερο ενεργειακό κόστος από τους συμβατικά προγραμματισμένους ομολόγους τους. Επομένως, οι παράλληλες προσεγγίσεις επεξεργασίας σήματος είναι πολύτιμες για τη βελτίωση της αποτελεσματικότητας και της ακρίβειας των μελλοντικών ραδιοεπαφών. Ο παράλληλος υπολογιστής με βάση τη μονάδα επεξεργασίας γραφικών (Graphics Processing Unit - GPU) επιτρέπει να εξαχθούν ακριβή συμπεράσματα εντός χιλιοστών του δευτερολέπτου (Zhang et al, 2019).

4.3 Περιορισμός του υπάρχοντος ασύρματου συστήματος

Για την επίλυση των πολύπλοκων ζητημάτων ραδιοεπικοινωνίας, χρησιμοποιείται ευρέως η προσέγγιση διαίρεσης και κατακράτησης. Κατά συνέπεια, τα υπάρχοντα συστήματα επικοινωνίας έχουν σχεδιαστεί με μια σειρά καθορισμένων μπλοκ, όπως κωδικοποίηση καναλιού και αποκωδικοποίηση, διαμόρφωση και αποδιαμόρφωση, κ.λπ. Τα προβλήματα ραδιοεπικοινωνίας συνήθως επιλύονται βελτιστοποιώντας κάθε μπλοκ λειτουργιών ανεξάρτητα. Παρόλο που πολλοί ερευνητές έχουν προσπαθήσει να βελτιστοποιήσουν κάθε συγκεκριμένο μπλοκ και έχουν επιτύχει συγκεκριμένα κέρδη στην πράξη, η βέλτιστη απόδοση ολόκληρου του συστήματος δεν είναι εγγυημένη. Ο λόγος πίσω από αυτό είναι ότι το βασικό πρόβλημα της επικοινωνίας εξαρτάται από την επιτυχή ανάκτηση μηνυμάτων από τον δέκτη αφού ο πομπός στέλνει το μήνυμα μέσω του ασύρματου καναλιού. Η διαδικασία δεν απαιτεί απαραίτητα τεχνητή δομή μπλοκ. Επομένως, θα πρέπει να βελτιστοποιηθεί η απόδοση του συστήματος από άκρο σε άκρο αντί να βελτιστοποιείται κάθε μπλοκ ανεξάρτητα. Από αυτήν την άποψη, η προσέγγιση εκμάθησης ενίσχυσης όπως ο αυτόματος κωδικοποιητής καθιστά δυνατή τη ολιστική βελτιστοποίηση της διεπαφής ασύρματου 6G από άκρο σε άκρο (Piran et al, 2019).

4.4 Διαφορετικές απαιτήσεις QoS / QoE

Το 6G έχει ως στόχο να υποστηρίζει διάφορες νέες εφαρμογές ΙοΕ (Ιντερνετ των Παντων) όπως XR, έξυπνη κατασκευή, έξυπνα περιβάλλοντα κ.λπ. Είναι δύσκολο να κατανοηθεί, να αξιολογηθεί και να διασφαλιστεί ικανοποιητικό QoS / QoE (Ποιότητα Υπηρεσίας / Ποιότητα Εμπειρίας) των αναδυόμενων εφαρμογών. Τα περισσότερα υπάρχοντα μοντέλα QoE περιορίζονται σε συμβατικές κινητές ευρυζωνικές υπηρεσίες

όπως το VoLTE και υπηρεσίες ροής. Για να καθορισθεί ένα ακριβές μοντέλο QoS / QoE, οι απαιτήσεις των χρηστών και τα χαρακτηριστικά των νέων εφαρμογών θα πρέπει να είναι κατανοητά σε βάθος. Οι τεχνικές μηχανικής μάθησης έχουν φανεί χρήσιμες για την εύρεση των συσχετίσεων μεταξύ μετρήσεων QoE σε επίπεδο εφαρμογής και δεικτών QoS σε επίπεδο δικτύου και κατανόησης της επίδρασης της QoS στη QoE. Επιπλέον, το 6G αναμένεται να παρέχει διάφορες υπηρεσίες με ολοκληρωμένη κάλυψη 3D διαστήματος-εναέρια-χερσαία-ωκεανού, έτσι είναι πολύ δύσκολο να διατηρηθεί μια συνεπής και ικανοποιητική εμπειρία χρήστη σε τόσο περίπλοκα και δυναμικά περιβάλλοντα δικτύου. Εκτός από τα υπάρχοντα αντιδραστικά QoS / QoE, οι προληπτικοί μηχανισμοί διαχείρισης QoS / QoE που βασίζονται στη συνειδητοποίηση συμπεριφοράς των χρηστών, στην ευαισθητοποίηση για την κατάσταση δικτύου και στην πρόβλεψη μελλοντικής ζήτησης έχουν μεγάλη σημασία. Η μηχανική μάθηση έχει αποδειχθεί ως μια αποτελεσματική προσέγγιση για την εκπλήρωση ακραίων και διαφορετικών απαιτήσεων από διάφορες νέες εφαρμογές, προβλέποντας συμπεριφορές χρηστών και απαιτήσεις κυκλοφορίας (Peltonen et al, 2020).

4.5 Σύνθετα και ευέλικτα δίκτυα

Το 6G αναμένεται να είναι ένα ολοκληρωμένο δίκτυο με διαφορετικά δίκτυα πρόσβασης που παρουσιάζουν ξεχωριστά χαρακτηριστικά. Επιπλέον, ως αποτέλεσμα των υπερβολικά πυκνών δικτύων και των ευέλικτων διαχωρισμών ανάμεσα στο επίπεδο ελέγχου και δεδομένων, υπάρχει σημαντική αύξηση του αριθμού των κόμβων δικτύου σε διάφορες μορφές όπως μακρο-σταθμός, μικρο-σταθμός, σταθμός Femto, κεντρική μονάδα (Central Unit - CU), κατανεμημένη μονάδα (Distributed Unit - DU), ενεργή μονάδα κεραίας (Active Antenna Unit - AAU), για διαχείριση από διαχειριστές δικτύου. Είναι όλο και πιο δύσκολο να διαμορφωθούν και να διαχειριστούν τόσο πολύπλοκα δίκτυα με συμβατικές προσεγγίσεις, οι οποίες βασίζονται σε μεγάλο βαθμό στα χέρια ανθρώπων. Μια πιθανή λύση για την ενίσχυση της νοημοσύνης του συστήματος διαχείρισης δικτύου είναι η αξιοποίηση του μηχανικής μάθησης για την επίτευξη του οράματος ενός αυτοσυντηρούμενου δικτύου, το οποίο αναμένεται όχι μόνο να προσαρμόσει τις λειτουργίες του δικτύου αλλά και να διατηρήσει τη χρήση των πόρων του δικτύου για να διατηρήσει αυτόνομα τη μακροπρόθεσμη απόδοση. Επιπλέον, ο τεμαχισμός δικτύου καθιστά δυνατή την παροχή διαφόρων

προσαρμοσμένων υπηρεσιών έναντι κοινών φυσικών υποδομών δικτύου. Ο μέχρι τώρα τεμαχισμός δικτύου πρέπει να κλιμακωθεί με ευελιξία για να ικανοποιήσει τις μεταβαλλόμενες απαιτήσεις των πελατών. Με έναν ολοένα και μεγαλύτερο αριθμό περιπτώσεων τεμαχισμού δικτύου σε διαστημικούς, εναέριους και επίγειους τομείς δικτύου, είναι πιο δύσκολο για τους χειριστές να διαχειρίζονται και να ενοποιούν αποτελεσματικά τους τεμαχισμένους πόρους του δικτύου 6G. Για το σκοπό αυτό, η μηχανική μάθηση είναι μια πολλά υποσχόμενη προσέγγιση για την ενεργοποιημένη διαχείριση έξυπνων δικτύων και ενορχήστρωση πόρων (Lu & Zheng, 2020).

4.6 Αποτελεσματική χρήση πόρων

Το υπάρχον οικοσύστημα επικοινωνίας με επίκεντρο τα smartphone εξελίσσεται σε ένα οικοσύστημα 6G IoE που ενσωματώνει διάφορες συσκευές όπως drones, συνδεδεμένα οχήματα, αισθητήρες κ.λπ. Ο μετασχηματισμός θα οδηγήσει σε εκθετική αύξηση της κυκλοφορίας δεδομένων. Για να παρέχουν υψηλούς ρυθμούς δεδομένων, τα δίκτυα 6G θα χρησιμοποιούν διάφορους πόρους φάσματος, όπως χαμηλή ραδιοσυχνότητα, mmWave, Terahertz και φάσμα ορατού φωτός. Είναι πολύ δύσκολο να χρησιμοποιηθούν αποτελεσματικά διάφοροι πόροι φάσματος για διαφορετικές εφαρμογές / χρήστες σε δυναμικά περιβάλλοντα δικτύου. Επιπλέον, οι διαθέσιμοι πόροι ραδιοσυχνοτήτων είναι αρκετά περιορισμένοι αν και χρησιμοποιείται φάσμα υψηλής συχνότητας όπως mmWave, THz. Επομένως, οι περιορισμένοι πόροι δικτύου πρέπει να χρησιμοποιούνται έξυπνα και εύελικτα για να ικανοποιούν διαφορετικές και μεταβαλλόμενες απαιτήσεις των χρηστών. Εκτός αυτού, τα μικροσκοπικά κύτταρα αναμένεται να εισαχθούν σε 6G για τη βελτίωση της χωρητικότητας του δικτύου αυξάνοντας την επαναχρησιμοποίηση του φάσματος. Ωστόσο, αυτό απαιτεί αποτελεσματική διαχείριση της αύξησης των παρεμβολών μεταξύ των κυττάρων. Για το σκοπό αυτό, το 6G θα πρέπει να απομακρυνθεί από τον συμβατικό προγραμματισμό πόρων δικτύου, προς μια περισσότερο σε έξυπνη διαχείριση πόρων που βασίζεται σε AI. Με τη βοήθεια της τεχνητής νοημοσύνης, διάφοροι πόροι φάσματος μπορούν να χρησιμοποιηθούν αποτελεσματικά για τη μετάδοση διαφορετικών κυκλοφοριών με διαφορετικές απαιτήσεις. Η βαθιά μάθηση ενίσχυσης καθιστά δυνατή τη δημιουργία ενός αυτοματοποιημένου πλαισίου βελτιστοποίησης κλειστού βρόχου για την αποτελεσματική χρήση διαφόρων πόρων δικτύου (Jiang et al, 2021).

4.7 Χαμηλότερη κατανάλωση ενέργειας

Η αύξηση της ενεργειακής απόδοσης του δικτύου κινητής τηλεφωνίας είναι χρήσιμη για τη μείωση των λειτουργικών δαπανών και των εκπομπών άνθρακα για βιώσιμη ανάπτυξη. Η έκρηξη δεδομένων σε συνδυασμό με τον ολοένα και μεγαλύτερο αριθμό μικροσκοπικών συσκευών καθιστά την κατανάλωση ενέργειας των 6G ένα ιδιαίτερα δύσκολο ζήτημα. Επιπλέον, η πολυπλοκότητα της επεξεργασίας πομποδεκτών και της αύξησης των εφαρμογών τελικού χρήστη μπορεί να οδηγήσει σε μεγαλύτερη κατανάλωση ενέργειας. Η ενεργειακή απόδοση μπορεί να βελτιωθεί με πολλές τεχνικές όπως η δυναμική λειτουργία κυψελών, η εκφόρτωση της κυκλοφορίας κ.λπ. Εν τω μεταξύ, η κατανάλωση ενέργειας μπορεί να μειωθεί με την αξιοποίηση των πράσινων ενεργειακών πόρων. Έχουν προταθεί μέθοδοι συλλογής ενέργειας, ταυτόχρονες ασύρματες πληροφορίες και μεταφορά ισχύος για την εκμετάλλευση της πράσινης ενέργειας από φυσικούς πόρους όπως ο ήλιος και ο άνεμος. Για να ξεπεραστεί η έλλειψη στοχαστικής και διαλείπουσας διαθεσιμότητας φυσικών πόρων, η κινητικότητα των χρηστών και τα χαρακτηριστικά κυκλοφορίας πρέπει να ληφθούν υπόψη για τη λήψη ενεργητικών μέτρων διαχείρισης της ενέργειας. Οι αλγόριθμοι μηχανικής μάθησης μπορούν να αξιοποιηθούν για να μάθουν το ασύρματο περιβάλλον και να αντλήσουν την κατάλληλη διαμόρφωση για την επίτευξη των αναμενόμενων στόχων. Για να βελτιστοποιηθεί η κατανάλωση ενέργειας, διασφαλίζοντας παράλληλα την εμπειρία του χρήστη, είναι σημαντικό να γίνουν κατανοητά τα δυναμικά μοτίβα κυκλοφορίας χρήστη και μοτίβα κινητικότητας, καιρικές καταστάσεις και να γίνουν προβλέψεις σχετικά με τη μελλοντική ζήτηση κυκλοφορίας και τη διαθεσιμότητα πράσινης ενέργειας. Ωστόσο, οι συμβατικές μέθοδοι βελτιστοποίησης και οι ευρετικοί αλγόριθμοι δεν επαρκούν για την εκτέλεση αυτών των πολύπλοκων εργασιών. Ευτυχώς, οι αλγόριθμοι μηχανικής μάθησης μπορούν να χρησιμοποιηθούν για να μάθουν τη βελτιστοποιημένη πολιτική για τον στόχο εξοικονόμησης ενέργειας (Tang et al, 2021).

4.8 Αύξηση της ασφάλειας και απειλών απορρήτου

Με τη δημοτικότητα και την εξέλιξη των συσκευών smartphone, κακόβουλα προγράμματα και εφαρμογές που έχουν μολυνθεί από ιούς οδηγούν σε πολλές απειλές για την ασφάλεια του δικτύου και το απόρρητο των χρηστών. Εκτός από την ευρυζωνική υπηρεσία κινητής τηλεφωνίας, το 6G αναμένεται να υποστηρίζει διάφορες

εφαρμογές ΙοΕ. Λόγω της περιορισμένης ικανότητας επεξεργασίας και της παροχής ενέργειας, είναι πιο δύσκολο να επιβληθεί επαρκής προστασία ασφάλειας για απλές συσκευές ΙοΤ. Το botnet γίνεται μια σοβαρή απειλή για τα δίκτυα κινητής τηλεφωνίας, ειδικά στην περίπτωση μαζικών σεναρίων ΙοΤ, όπου μεγάλος αριθμός φθηνών συσκευών βρίσκονται υπό υψηλό κίνδυνο παραβίασης. Η αποτελεσματική ανίχνευση του botnet είναι πρόκληση και κρίσιμη για την ασφάλεια δικτύου 6G. Επιπλέον, η ευαισθητοποίηση του κοινού για την προστασία της ιδιωτικής ζωής έχει αυξηθεί σημαντικά, γεγονός που οδηγεί σε περισσότερες ανησυχίες σχετικά με τη διαρροή απορρήτου των χρηστών. Με τα επερχόμενα έξυπνα περιβάλλοντα, όπως στην υγειονομική περίθαλψη, τα αυτόνομα οχήματα, υπάρχουν υψηλότερες απαιτήσεις για προστασία της ιδιωτικής ζωής. Επιπλέον, η μηχανική μάθηση έχει χρησιμοποιηθεί και για κυβερνοεπιθέσεις, όπως η δημοσιοποίηση κωδικών ασφαλείας των χρηστών ή η παραβίαση των πληροφοριών απορρήτου των χρηστών. Εν τω μεταξύ, η μηχανική μάθηση έχει χρησιμοποιηθεί ευρέως σε εφαρμογές ασφάλειας στον κυβερνοχώρο, όπως ανίχνευση εισβολής, ανίχνευση ανωμαλιών, ανίχνευση botnet, ευαισθητοποίηση σχετικά με την κατάσταση ασφαλείας κ.λπ. Με τη βοήθεια της μηχανικής μάθησης, είναι δυνατό να δημιουργηθεί ένα πλαίσιο προστασίας ασφαλείας κλειστού βρόχου, όπου η ασυνήθιστη συλλογή, κίνηση, εξόρυξη δεδομένων, ανίχνευση / πρόβλεψη κινδύνου, έλεγχος πολιτικής / λήψη αποφάσεων, ενορχήστρωση πόρων ασφαλείας, επιβολή πολιτικής ασφαλείας μπορεί να εκτελεστεί αυτόματα για έξυπνη, προληπτική, ευέλικτη προστασία ασφαλείας στο 6G (Monserrat et al, 2020).

5 Τελευταίες Εξελίξεις της Τεχνητής Νοημοσύνης


Η τεχνητή νοημοσύνη είναι μια διεπιστημονική επιστήμη που αναπτύσσει θεωρίες, τεχνικές, μεθόδους προσομοίωσης και επέκτασης της ανθρώπινης νοημοσύνης. Η ΑΙ προσπαθεί να κατανοήσει την ουσία της νοημοσύνης και να προσομοιώσει την επεξεργασία πληροφοριών του ανθρώπινου εγκεφάλου σε μηχανές. Ως κλάδος της τεχνητής νοημοσύνης, η μηχανική μάθηση σχετίζεται με υπολογιστικές στατιστικές και προβλέψεις αξιοποιώντας την εμπειρία και τις γνώσεις που αποκτήθηκαν από τα δεδομένα. Η μάθηση δεδομένων είναι ουσιαστικά ένας κλάδος της μηχανικής μάθησης, η οποία επιτρέπει σε ένα μοντέλο να κάνει ταξινομήσεις, προβλέψεις ή αποφάσεις που βασίζονται σε μεγάλα σύνολα δεδομένων, χωρίς να έχει προγραμματιστεί ρητά (Zhao 2020).

5.1 Μηχανική Εκμάθηση

Η μηχανική μάθηση αφορά την εκμάθηση από δεδομένα και τη λήψη αποφάσεων ή προβλέψεων. Βασικά βασίζεται στην υπόθεση ότι οι μηχανές μπορούν να αποκτήσουν ευφυΐα που τους επιτρέπει να μάθουν από προηγούμενους υπολογισμούς και να προσαρμοστούν στο περιβάλλον. Η ιστορία της μηχανικής μάθησης χρονολογείται από το 1943 όταν το μαθηματικό μοντέλο του νευρικού δικτύου (Neural Network - NN) για υπολογιστές προτάθηκε για πρώτη φορά από τον McCulloch. Το τυπικό πλαίσιο μηχανικής μάθησης περιλαμβάνει μια διαδικασία εκπαίδευσης και μια διαδικασία δοκιμών. Η πρώτη επιτρέπει στο πλαίσιο μηχανικής μάθησης να ανακαλύψει τις σχέσεις μεταξύ δεδομένων εισόδου και δεδομένων εξόδου. Τα υπάρχοντα μοντέλα μηχανικής μάθησης μπορούν να ταξινομηθούν σε μοντέλα ταξινόμησης, μοντέλα παλινδρόμησης και δομημένα μοντέλα μάθησης. Τα μοντέλα ταξινόμησης χρησιμοποιούνται για την επίλυση δυαδικών ταξινομήσεων ή πολλαπλών προβλημάτων ταξινόμησης. Το μοντέλο παλινδρόμησης μπορεί να χρησιμοποιηθεί για την εκτέλεση προβλέψεων. Το μοντέλο εκμάθησης δομών χρησιμοποιείται ευρέως σε πολλούς τομείς, όπως η επεξεργασία φυσικής γλώσσας, κ.λπ. Σύμφωνα με τη μέθοδο εκπαίδευσης, η μηχανική μάθηση μπορεί να κατηγοριοποιηθεί σε εποπτευόμενη μάθηση, μη εποπτευόμενη μάθηση και μάθηση ενίσχυσης (Reinforcement Learning - RL) (Nayak et al, 2021).

Το σχήμα δείχνει την ταξινόμηση των κύριων τεχνικών μηχανικής μάθησης.

Εικόνα 4 ταξινόμηση των κύριων τεχνικών μηχανικής μάθησης



(Letaief et al, 2019)

5.1.1 Εποπτευόμενη μάθηση

Η εποπτευόμενη μάθηση απαιτεί από έναν επόπτη να επισημαίνει τα δεδομένα εισόδου και τα δεδομένα εξόδου. Στη φάση της εκπαίδευσης, ο αλγόριθμος εκμάθησης τροφοδοτείται με ένα σύνολο ετικετών εκπαιδευτικών δεδομένων που περιέχει είσοδο και γνωστή έξοδο για την εκπαίδευση ενός μοντέλου που αντιπροσωπεύει τις σχέσεις μεταξύ εισόδου και εξόδου. Στη φάση δοκιμής, ένα νέο σύνολο δεδομένων δοκιμής τροφοδοτείται στο μοντέλο που έχει μάθει για να παραχθεί η αναμενόμενη έξοδος. Η εποπτευόμενη μάθηση χρησιμοποιείται συνήθως σε σενάρια με αρκετά επισημασμένα δεδομένα. Η μέθοδος έχει χρησιμοποιηθεί ευρέως σε πολλά πεδία, όπως αναγνώριση αντικειμένων, αναγνώριση ομιλίας και ανίχνευση ανεπιθύμητων μηνυμάτων. Τυπικοί αλγόριθμοι σε αυτήν την κατηγορία περιλαμβάνουν Naive Bayes, K-πλησιέστερου

γείτονα (K-Nearest Neighbor - KNN), τυχαίου δάσους, νευρικά δίκτυα (NN), και δέντρα αποφάσεων (Decision Trees - DT) (Kato et al, 2020).

KNN: Το KNN είναι ένας αλγόριθμος ταξινόμησης που βασίζεται στη μέτρηση της απόστασης μεταξύ διαφορετικών τιμών χαρακτηριστικών. Η ταξινόμηση ενός δείγματος δεδομένων καθορίζεται με βάση την κατηγορία των πλησιέστερων γειτόνων K. Εάν οι περισσότεροι από τους πλησιέστερους γείτονες του K στο χώρο χαρακτηριστικών ανήκουν σε μια συγκεκριμένη κατηγορία, τότε το δείγμα κατηγοριοποιείται στην ίδια κατηγορία. Ο αλγόριθμος είναι εύκολο να γίνει αντιληπτός, μη ευαίσθητος στα ακραία σημεία και είναι κατάλληλος για ταξινομήσεις πολλών κλάσεων. Αλλά είναι πολύ χρονοβόρο όταν χρησιμοποιείται για μεγάλα σύνολα δεδομένων (Tang et al, 2019).

Δέντρο απόφασης: Κάθε κόμβος του δέντρου αποφάσεων αντιπροσωπεύει ένα χαρακτηριστικό δεδομένων, κάθε κλάδος αντιπροσωπεύει το συνδυασμό χαρακτηριστικών που οδηγούν σε ταξινόμηση και κάθε κόμβος φύλλων αντιπροσωπεύει μια συγκεκριμένη κλάση. Το δέντρο αποφάσεων έχει δημιουργηθεί για να μεγιστοποιεί το κέρδος πληροφοριών κάθε διαίρεσης μεταβλητής, το οποίο οδηγεί σε φυσική κατάταξη μεταβλητών. Τα ID3 και C4.5 είναι γνωστοί αλγόριθμοι για την αυτόματη δημιουργία δέντρων αποφάσεων. Η ταξινόμηση του δείγματος χωρίς ετικέτα μπορεί να επιτευχθεί συγκρίνοντας την τιμή χαρακτηριστικού του με τους κόμβους του δέντρου αποφάσεων, το οποίο εκπαιδεύεται από το σύνολο δεδομένων με ετικέτα. Τα κύρια πλεονεκτήματα περιλαμβάνουν υψηλή ακρίβεια ταξινόμησης, απλή εφαρμογή και διαισθητική έκφραση. Ωστόσο, υποφέρει από δεδομένα, συμπεριλαμβανομένων κατηγορηματικών μεταβλητών με διαφορετικό αριθμό επιπέδων, διότι τα κέρδη πληροφοριών θα επηρεαστούν με χαρακτηριστικά με περισσότερα επίπεδα (Sun et al, 2020).

Τυχαίο δάσος: Ένα τυχαίο δάσος αποτελείται συνήθως από δέντρα πολλαπλών αποφάσεων. Για τον μετριασμό των υπερβολικών ζητημάτων του δέντρου αποφάσεων, η μέθοδος επιλέγει τυχαία ένα υποσύνολο χαρακτηριστικών για την κατασκευή κάθε δέντρου αποφάσεων. Ένα νέο σύνολο δεδομένων ταξινομείται από κάθε δέντρο αποφάσεων και, στη συνέχεια, το δείγμα δεδομένων κατηγοριοποιείται σε μια κατηγορία που συμφωνείται από τα περισσότερα δέντρα (Hoyidis et al, 2020).

Νευρικό δίκτυο: Το νευρικό δίκτυο μπορεί να χρησιμοποιηθεί για την εκμάθηση βιωματικών γνώσεων από ιστορικά δεδομένα από μεγάλο αριθμό μονάδων επεξεργασίας, οι οποίες λειτουργούν παράλληλα. Οι συναρτήσεις ενεργοποίησης όπως

το σιγμοειδές και οι υπερβολικές εφραπτόμενες συναρτήσεις συνήθως εφαρμόζονται σε αυτές τις μονάδες για την πραγματοποίηση μη γραμμικών υπολογισμών. Ένα νευρικό δίκτυο έχει συνήθως ένα επίπεδο εισόδου, ένα επίπεδο εξόδου και ένα ή περισσότερα κρυφά επίπεδα. Ρυθμίζοντας τον αριθμό των κρυφών επιπέδων και τον αριθμό των μονάδων σε κάθε επίπεδο, μπορούν να εκπαιδευτούν διαφορετικά μοντέλα για την επίλυση προβλημάτων ταξινόμησης ή παλινδρόμησης. Το μοντέλο των νευρικών δικτύων μπορεί να εκπαιδευτεί με εποπτευόμενη μάθηση ή μη εποπτευόμενη μάθηση (Nawaz et al, 2019).

Naive Bayes: είναι μια απλή πιθανολογική προσέγγιση ταξινόμησης με βάση το θεώρημα Bayes. Οι ταξινομητές μπορούν να χειριστούν αποτελεσματικά έναν μεγάλο αριθμό συνεχών ή κατηγορηματικών χαρακτηριστικών που είναι ανεξάρτητα επειδή μπορεί να μετατρέψει μια εργασία εκτίμησης πυκνότητας υψηλής διάστασης σε μια μονοδιάστατη εκτίμηση για την πυκνότητα του πυρήνα με βάση την υπόθεση ότι τα χαρακτηριστικά είναι ανεξάρτητα. Ο ταξινομητής Bayes μπορεί να χρησιμοποιηθεί ως διαδικτυακός αλγόριθμος, δεδομένου ότι μπορεί να εκπαιδευτεί σε γραμμικό χρόνο (Kaur et al, 2021).

5.1.2 Μη εποπτευόμενη μάθηση

Στους αλγορίθμους μάθησης χωρίς επίβλεψη παρέχεται ένα σύνολο εισόδου χωρίς ετικέτα για να συμπεράνει σωστά την έξοδο. Οι τεχνικές χρησιμοποιούνται συνήθως για ομαδοποίηση και συγκέντρωση. Τυπικοί μη εποπτευόμενοι αλγόριθμοι περιλαμβάνουν το Kmeans, τους αυτο-οργανωμένους χάρτες (Self-Organizing Maps - SOM), το κρυφό μοντέλο Markov (Hidden Markov Model - HMM), τον περιορισμένη μηχανή Boltzmann (Restricted Boltzmann machine - RBM) (Ali et al, 2020).

K-μέσα: Χρησιμοποιείται ευρέως για την ταξινόμηση ενός συνόλου δεδομένων χωρίς ετικέτα σε διαφορετικές ομάδες. Το K αντιπροσωπεύει τον αριθμό των επιθυμητών συστάδων. Η αντικειμενική συνάρτηση του k-σημαίνει αντιπροσωπεύει την απόσταση μεταξύ δεδομένων και συναφών κεντροειδών. Τα K-μέσα τείνουν να εκχωρούν κάθε δεδομένα σε ένα σύμπλεγμα με το κεντροειδές που βρίσκεται πλησιέστερα στα δεδομένα. Η διαδικασία ενημέρωσης του κεντροειδούς με βάση ένα καθορισμένο σημείο δεδομένων θα επαναληφθεί έως ότου δεν αλλάξει κανένα σημείο ή το κεντροειδές. Η επιλογή του K έχει μεγάλο αντίκτυπο στην απόδοση του αλγορίθμου. (Loven et al, 2019).

Αυτο-οργανωμένος χάρτης: Χρησιμοποιείται συχνά για την πραγματοποίηση μείωσης διαστάσεων και ομαδοποίησης δεδομένων. Περιέχει ένα επίπεδο εισόδου και ένα επίπεδο χάρτη. Κάθε επίπεδο περιλαμβάνει πολλούς νευρώνες και κάθε νευρώνας έχει φορέα βάρους. Κατά τη διάρκεια της εκπαιδευτικής διαδικασίας, μπορεί να δημιουργήσει και να αναδιοργανώσει τον χάρτη. Σε αντίθεση με τα συμβατικά νευρικά δίκτυα που εφαρμόζουν μάθηση διόρθωσης σφαλμάτων, οι αυτό-οργανωμένοι χάρτες χρησιμοποιούν μια μη εποπτευόμενη προσέγγιση ανταγωνιστικής μάθησης [83]. Μετά την εκπαίδευση, ένας νέος φορέας εισόδου ταξινομείται σε ένα σύμπλεγμα με βάση τον νευρώνα που κερδίζει στον χάρτη. Οι τεχνικές έχουν χρησιμοποιηθεί με επιτυχία σε διάφορες εργασίες αναγνώρισης προτύπων (Zhang et al, 2019).

Κρυφό μοντέλο Markov: Η προσέγγιση μπορεί να χρησιμοποιηθεί για τη μοντελοποίηση ενός συστήματος με μια διαδικασία Markov με άγνωστες παραμέτρους. Η κύρια πρόκληση είναι ο προσδιορισμός των κρυφών παραμέτρων από γνωστές παραμέτρους. Τα μοντέλα Markov χρησιμοποιούνται ευρέως σε τυχαία δυναμικά σενάρια με ιδιότητα χωρίς μνήμη, πράγμα που σημαίνει ότι η υπό όρους πιθανότητα κατανομής μελλοντικών καταστάσεων εξαρτάται μόνο από την τρέχουσα κατάσταση. Οι παράμετροι του μπορούν να εκπαιδευτούν με εποπτεία ή χωρίς. Το Μπορεί να χρησιμοποιηθεί για την αναπαράσταση μη στατικών αλληλουχιών, η οποία επιτρέπει στο σύστημα να αλλάζει με την πάροδο του χρόνου με διαφορετικές κατανομές πιθανότητας εξόδου από κάθε κατάσταση (Du et al, 2020).

Περιορισμένη μηχανή Boltzmann: Αντιπροσωπεύει ένα στοχαστικό νευρικό δίκτυο που αποτελείται από δύο στρώματα: το στρώμα εισόδου και το κρυφό στρώμα. Σε σύγκριση με τη βασική μηχανή Boltzmann, σε αυτή τη περίπτωση δεν επιτρέπεται η σύνδεση μεταξύ δύο μονάδων στο ίδιο στρώμα. Η διαδικασία εκμάθησης του είναι αποτελεσματική χάρη στον περιορισμό των συνδέσεων σε οποιοδήποτε επίπεδο. Μόλις εκπαιδευτεί, οι δραστηριότητες των κρυφών μονάδων μπορούν να χρησιμοποιηθούν για την εκπαίδευση μιας αντίστοιχης μηχανής υψηλότερου επιπέδου. Η μέθοδος καθιστά δυνατή την αποτελεσματική με πολλά κρυφά στρώματα. Μετά την προ-εκπαίδευση, μπορεί να ξεδιπλωθεί για να δημιουργήσει ένα βαθύ δίκτυο που μπορεί να ρυθμιστεί από τον αλγόριθμο οπίσθιας διάδοσης. Καθώς η μέθοδος μπορεί να εκπαιδευτεί με εποπτευόμενους ή μη εποπτευόμενους τρόπους, είναι χρήσιμη σε μια ποικιλία τομέων όπως η εκμάθηση χαρακτηριστικών, η ταξινόμηση και η μείωση των διαστάσεων (Tmkos et al, 2020).

5.1.3 Semi-supervised learning

Η ημι-εποπτευόμενη μάθηση (Semi-supervised learning) είναι ένας συνδυασμός της εποπτευόμενης μάθησης και της μη εποπτευόμενης μάθησης. Σε πολλά σενάρια πραγματικού κόσμου, η παραγωγή μεγάλου όγκου δεδομένων με σήμανση είναι δαπανηρή και χρονοβόρα, ενώ είναι σχετικά φθηνή και βολική η συλλογή επαρκών δεδομένων χωρίς σήμανση. Ως εκ τούτου, η Semi-supervised learning αναπτύσσεται για να αξιοποιεί πλήρως τα δεδομένα χωρίς σήμανση για τη βελτίωση της απόδοσης του εκπαιδευμένου μοντέλου. Ως τυπικό παράδειγμα του ημι-εποπτευόμενου αλγορίθμου μάθησης, η ψευδοσήμανση είναι απλή και αποτελεσματική. Τα περιορισμένα δεδομένα με σήμανση χρησιμοποιούνται για την εκπαίδευση ενός μοντέλου. Στη συνέχεια, το εκπαιδευμένο μοντέλο χρησιμοποιείται για τη δημιουργία ψευδών σημάνσεων για τα δεδομένα χωρίς σήμανση. Τέλος, τα επισημασμένα δεδομένα και τα ψευδο-επισημασμένα δεδομένα χρησιμοποιούνται για την επανεκπαίδευση του μοντέλου. Για να αξιοποιηθούν πλήρως τα δεδομένα χωρίς σήμανση, οι ημι-εποπτευόμενοι αλγόριθμοι μάθησης συνήθως απαιτούν ορισμένες παραδοχές στο σύνολο δεδομένων, όπως πολλαπλή υπόθεση, υπόθεση χαμηλής πυκνότητας, υπόθεση συμπλέγματος και υπόθεση ομαλότητας. Για παράδειγμα, η μεγιστοποίηση προσδοκίας βασίζεται στην παραδοχή συστάδων, ενώ το διαγωγικό SVM απαιτεί την υπόθεση διαχωρισμού χαμηλής πυκνότητας (Cousik et al, 2019).

5.1.4 Μάθηση ενίσχυσης

Η κύρια ιδέα της μάθησης ενίσχυσης είναι να μιμηθεί τη μαθησιακή διαδικασία του εγκεφάλου με δοκιμή και σφάλμα. Αντί να μάθει τη δομή του συνόλου δεδομένων κατάρτισης, η μάθηση ενίσχυσης προσπαθεί να διερευνήσει τις καλύτερες ενέργειες κατά τη διάρκεια μιας δυναμικής διαδικασίας. Η ικανότητα κατανόησης του περιβάλλοντος μέσω ενεργειών και ανατροφοδότησης τη καθιστά κατάλληλη για την επίλυση ζητημάτων λήψης αποφάσεων. Η μάθηση ενίσχυσης μπορεί να κατηγοριοποιηθεί σε δύο τύπους: βάσει μοντέλου και χωρίς μοντέλο. Το πλαίσιο μάθησης ενίσχυσης που βασίζεται σε μοντέλο περιλαμβάνει έναν παράγοντα, έναν χώρο κατάστασης και έναν χώρο δράσης. Μέσω της αλληλεπίδρασης με το περιβάλλον, ο παράγοντας προσπαθεί να αντιπροσωπεύσει το μοντέλο του περιβάλλοντος και να μάθει την καλύτερη δράση για να μεγιστοποιήσει τη μακροπρόθεσμη ανταμοιβή του, η οποία είναι μια αθροιστική μειωμένη ανταμοιβή και

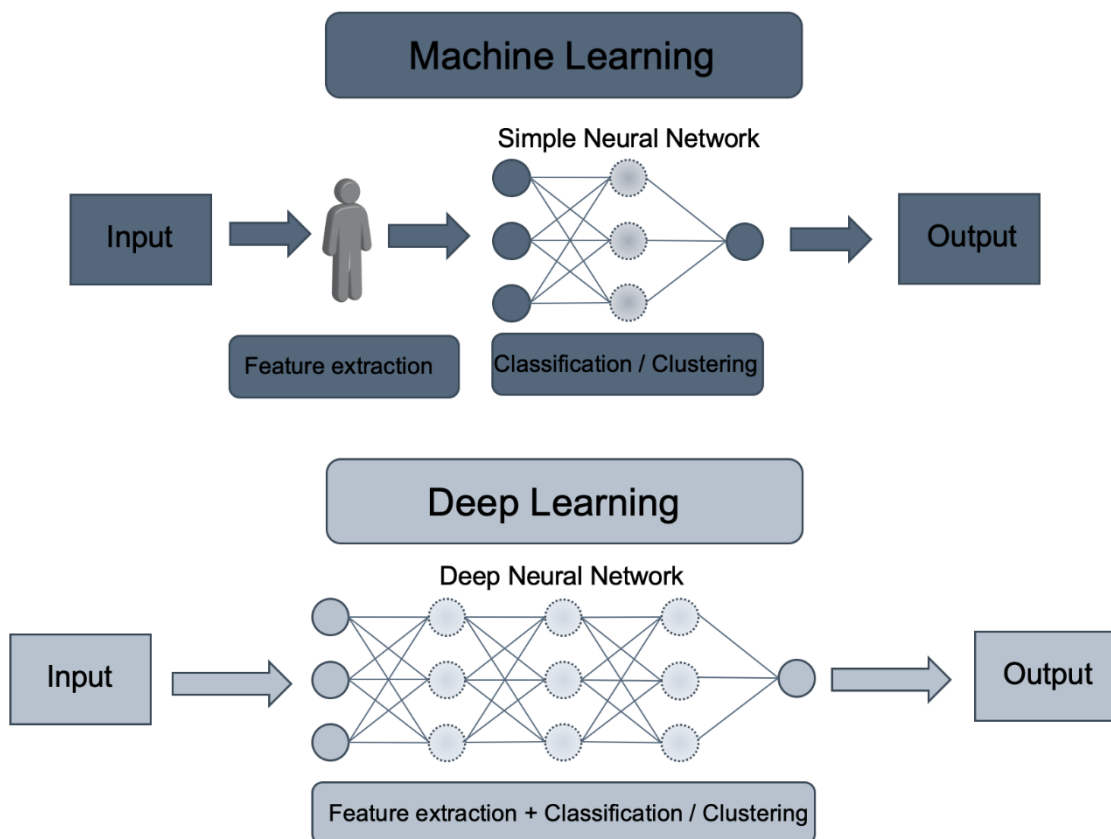
σχετίζεται με τις τρέχουσες ανταμοιβές και τις μελλοντικές ανταμοιβές. Σε κάθε βήμα, ο παράγοντας παρακολουθεί μια κατάσταση και λαμβάνει μια ενέργεια από το χώρο δράσης, στη συνέχεια λαμβάνει μια άμεση ανταμοιβή που δείχνει την επίδραση της ενέργειας και στη συνέχεια το σύστημα μετακινείται σε άλλη κατάσταση. Σε προσεγγίσεις χωρίς μοντέλα, ο παράγοντας προσπαθεί να μάθει μια πολιτική. Κατά τη διαδικασία μετάβασης κατάστασης, μαθαίνει την καλύτερη πολιτική που είναι ένας χάρτης από τον χώρο κατάστασης στο χώρο δράσης για τη μεγιστοποίηση της μακροπρόθεσμης επιβράβευσης. Για τον προσδιορισμό της μακροπρόθεσμης επιβράβευσης της ενέργειας σε χώρο κατάστασης, εφαρμόζεται η συνάρτηση τιμής. Η πιο ευρέως χρησιμοποιούμενη συνάρτηση τιμής είναι η συνάρτηση Q, η οποία χρησιμοποιείται από τη μέθοδο Q-learning για να μάθει έναν πίνακα να διατηρεί ζεύγη κατάστασης-δράσης και να συσχετίζει μακροπρόθεσμες ανταμοιβές. Η μάθηση ενίσχυσης βασισμένη σε μοντέλα είναι πιο κατάλληλη για δίκτυα κινητής τηλεφωνίας λόγω της δυσκολίας κατασκευής ενός ακριβούς μοντέλου δυναμικών δικτύων. Σε σύγκριση με άλλες τεχνικές μάθησης, το μεγαλύτερο πλεονέκτημα της μάθησης ενίσχυσης είναι ότι δεν εξαρτάται από ένα ακριβές μαθηματικό μοντέλο του περιβάλλοντος. Εκτός αυτού, η προσέγγιση αντιμετωπίζει τις μακροπρόθεσμες ανταμοιβές, συμπεριλαμβανομένων τόσο των άμεσων ανταμοιβών όσο και εκείνων στο μέλλον, γεγονός που επιτρέπει το αποτέλεσμα μακροπρόθεσμης βελτιστοποίησης. Ο τρόπος σχεδιασμού της κατάστασης του συστήματος, της δράσης, της ανταμοιβής σε διαφορετικά σενάρια για τη σύγκλιση της βέλτιστης απόδοσης είναι η κύρια πρόκληση της εφαρμογής μάθησης ενίσχυσης στο ασύρματο σύστημα επικοινωνίας. Τα τελευταία χρόνια, έχει χρησιμοποιηθεί ευρέως για την επίλυση των ζητημάτων λήψης αποφάσεων των ασύρματων επικοινωνιών, όπως ο προγραμματισμός χρηστών, η κοινή χρήση φάσματος, η μεταφορά τεχνολογίας ραδιοπρόσβασης. Ωστόσο, η τεχνική αντιμετωπίζει ορισμένες προκλήσεις στο χειρισμό προβλημάτων με ένα μεγάλο χώρο κατάστασης ή χώρο δράσης, επειδή είναι πολύ δύσκολο να μοντελοποιηθεί κάθε ζεύγος κατάστασης-δράσης άμεσα. Κατά συνέπεια, η μάθηση ενίσχυσης σπάνια χρησιμοποιείται στην πράξη (Catak et al, 2021).

5.2 Βαθιά Μάθηση

Σε αντίθεση με τους συμβατικούς αλγόριθμους μηχανικής μάθησης που βασίζονται σε προκαθορισμένα χαρακτηριστικά, η βαθιά μάθηση μπορεί να εξαγάγει βασικά

χαρακτηριστικά από ανεπεξέργαστα δεδομένα μέσω πολλαπλών επιπέδων μη γραμμικών μονάδων επεξεργασίας για να κάνει προβλέψεις ή να προβεί σε ενέργειες βάσει του στόχου. Τα κύρια πλεονεκτήματα της είναι η αυτόματη εξαγωγή χαρακτηριστικών. Τα πιο γνωστά μοντέλα είναι νευρικά δίκτυα με επαρκή αριθμό κρυφών επιπέδων. Παρόλο που το νευρικό δίκτυο πολλαπλών επιπέδων προτάθηκε πριν από αρκετές δεκαετίες, προσελκύει άνευ προηγουμένου ενδιαφέρον πρόσφατα χάρη στην ανακάλυψη της εκπαίδευσης με βάση τη μετάδοση και την επιτυχία της GPU.


Εικόνα 5 Η βαθιά μάθηση αποτελείται από μία είσοδο, μία έξοδο και πολλά εντελώς ενδιάμεσα πολλαπλά κρυμμένα στρώματα. Κάθε στρώμα παρουσιάζεται ως μια σειρά νευρώνων και εξάγει χαρακτηριστικά υψηλότερου επιπέδου των δεδομένων έως ότου το τελικό στρώμα ουσιαστικά αποφασίσει τι δείχνει η είσοδος. Όσο περισσότερα επίπεδα έχουν τα δίκτυα, θα μάθουν τα χαρακτηριστικά υψηλότερου επιπέδου.



Ο κύριος στόχος του βαθιού νευρικού δικτύου (Deep Neural Network - DNN) είναι η προσέγγιση τυχόν σύνθετων λειτουργιών με μια σύνθεση απλών χειρισμών σε νευρώνες. Η βαθιά μάθηση μπορεί αυτόματα να εξαγάγει βασικά χαρακτηριστικά από δεδομένα εισόδου με πολύπλοκη δομή. Δεν χρειάζεται μια διαδικασία μάθησης

σχεδιασμένη από τον άνθρωπο, η οποία μειώνει σημαντικά την προσπάθεια χειροτεχνίας χαρακτηριστικών. Μπορεί να μάθει πολύτιμα μοτίβα από δεδομένα χωρίς σήμανση και χωρίς επίβλεψη. Η κύρια πρόκληση της χρήσης βαθιάς μάθησης στο σύστημα κινητής επικοινωνίας έγκειται στο σχεδιασμό βέλτιστων δικτύων νευρικών βαθμών για διαφορετικά σενάρια, έτσι ώστε το μοντέλο να μπορεί να εκπαιδευτεί αποτελεσματικά στο στάδιο εκτός σύνδεσης και να επιτύχει καλή απόδοση στο στάδιο των διαδικτυακών δοκιμών. Τα τυπικά μοντέλα περιλαμβάνουν πολυεπίπεδο perceptron (Multi-level Perceptron - MLP), δίκτυο βαθιάς πεποίθησης (Deep Belief Network - DBN), αυτόματους κωδικοποιητές, συνελκτικό νευρικό δίκτυο (Convolutional Neural Network - CNN), επαναλαμβανόμενο νευρικό δίκτυο (Recurrent Neural Network - RNN), γενετικό δίκτυο αντιπαραθέσεων (GAN) (Rodrigues et al, 2019).

Εικόνα 6 Αναπαράσταση εικόνων σε πολλαπλά επίπεδα αφαίρεσης στη βαθιά μάθηση



5.2.1 Πολυεπίπεδο perceptron

Το πολυεπίπεδο perceptron (MLP) είναι ένα πρωτεύον μοντέλο τεχνητού νευρικού δικτύου (Artificial Neural Network - Artificial Neural Network), το οποίο αποτελείται από τουλάχιστον τρία επίπεδα: ένα επίπεδο εισόδου, περισσότερα από ένα κρυμμένα επίπεδα και ένα επίπεδο εξόδου. Απαιτεί οι μονάδες σε γειτονικά επίπεδα να είναι πυκνά συνδεδεμένες, επομένως πρέπει να εκπαιδευτεί ένας μεγάλος αριθμός παραμέτρων βάρους. Το μοντέλο MLP μπορεί να χρησιμοποιηθεί για εποπτευόμενη μάθηση, μη εποπτευόμενη μάθηση και την μάθηση ενίσχυσης. Αν και το μοντέλο χρησιμοποιήθηκε ευρέως στο παρελθόν, δεν χρησιμοποιείται συχνά λόγω της υψηλής πολυπλοκότητας, της χαμηλής ταχύτητας σύγκλισης και της μέτριας απόδοσης. Το MLP μπορεί να χρησιμοποιηθεί ως βασική γραμμή για προηγμένες αρχιτεκτονικές. Για παράδειγμα, το προηγμένο προσαρμοστικό νευρικό δίκτυο μάθησης (AdaNet) επιτρέπει να προσαρμόζουν δυναμικά τις δομές τους στο σύνολο δεδομένων εκπαίδευσης, το οποίο μπορεί να διερευνηθεί για βελτιστοποίηση συνεχώς μεταβαλλόμενων δικτύων κινητής τηλεφωνίας (Xiao et al, 2020).

5.2.2 Δίκτυο βαθιάς πεποίθησης

Το δίκτυο βαθιάς πεποίθησης (DBN) είναι ένας τύπος νευρικού δικτύου δημιουργίας που αντιπροσωπεύει το πρώτο επιτυχημένο μοντέλο βαθιάς μάθησης. Ένα δίκτυο βαθιάς πεποίθησης μπορεί να δημιουργηθεί με το στοίβαγμα αρκετών περιορισμένων μηχανών Boltzmann. Η εκπαίδευση ενός δικτύου βαθιάς πεποίθησης μπορεί να πραγματοποιηθεί επίπεδο ανά επίπεδο, όπου κάθε επίπεδο αντιμετωπίζεται ως περιορισμένη μηχανή Boltzmann εκπαιδευμένη πάνω από το προηγούμενως εκπαιδευμένο στρώμα. Η εκπαίδευση από πλευράς επιπέδου καθιστά το δίκτυο βαθιάς πεποίθησης ως ένα αποτελεσματικό μοντέλο μηχανικής μάθησης. Το δίκτυο βαθιάς πεποίθησης μπορεί να χρησιμοποιήσει μη εποπτευόμενη μάθηση για να εξαγάγει πολλαπλά επίπεδα λειτουργιών που χρησιμοποιούνται στο δίκτυο πρόωθησης. Η εποπτευόμενη προ-κατάρτιση καθιστά το δίκτυο βαθιάς πεποίθησης λιγότερο επιρρεπές σε υπερβολικά προβλήματα. Είναι κατάλληλα για την ανακάλυψη ιεραρχικών χαρακτηριστικών και επιτυγχάνουν καλή απόδοση σε πολλές εφαρμογές όπως η πρόβλεψη (Dang et al, 2020).

5.2.3 *Αυτόματος κωδικοποιητής*

Ο αυτόματος κωδικοποιητής (Auto-Encoder - AE) αναφέρεται σε ένα ειδικό είδος νευρικού δικτύου που στοχεύει στην εκμάθηση αποτελεσματικής κωδικοποίησης κωδικοποιώντας το σύνολο δεδομένων εισόδου. Τα κωδικοποιημένα δεδομένα αντιπροσωπεύουν μια συμπιεσμένη μορφή του συνόλου δεδομένων εισόδου. Οι αυτόματοι κωδικοποιητές έχουν σχεδιαστεί ως μια μη ελεγχόμενη μαθησιακή προσέγγιση για να μάθουν τη συμπαγή αναπαράσταση των δεδομένων εισαγωγής. Επομένως, ο αυτόματος κωδικοποιητής μπορεί να χρησιμοποιηθεί για την εκτέλεση συμπίεσης δεδομένων ή μείωσης διαστάσεων. Το τυπικό μοντέλο αυτόματου κωδικοποιητή περιλαμβάνει ένα επίπεδο εισόδου, ένα ή περισσότερα κρυφά επίπεδα και ένα επίπεδο εξόδου. Τα κρυφά επίπεδα χρησιμοποιούνται για την κωδικοποίηση του συνόλου δεδομένων εισόδου ενώ το επίπεδο εξόδου προσπαθεί να ανακατασκευάσει το επίπεδο εισόδου από το κωδικοποιημένο σύνολο δεδομένων. Στους συμβατικούς αυτόματους κωδικοποιητές, το κρυφό επίπεδο είναι πολύ μικρότερο από το επίπεδο εισόδου και εξόδου. Ένας αυτόματος κωδικοποιητής μπορεί να χρησιμοποιηθεί για την εξαγωγή μοτίβων από δεδομένα κινητής χωρίς σήμανση, και τα μοτίβα στη συνέχεια χρησιμοποιούνται για διάφορες εποπτευόμενες μαθησιακές εργασίες. Με βάση τη βασική δομή αυτόματου κωδικοποιητή, ο προηγμένος αυτόματος κωδικοποιητής εκκαθάρισης (Denoising Auto-Encoder - DAE) έχει αναπτυχθεί για την ανακατασκευή της εισόδου από μια θορυβώδη έκδοση των δεδομένων εισόδου. Με τη χρήση πολλαπλών επιπέδων αυτόματων κωδικοποιητών, ο συσσωρευμένος αυτόματος κωδικοποιητής μπορεί να εκπαιδευτεί σε σειρά για να συμπιέσει σταδιακά τις πληροφορίες εισαγωγής (Dang et al, 2020).

5.2.4 *Συνελκτικό νευρικό δίκτυο*

Το συνελκτικό νευρικό δίκτυο (Convolutional Neural Network - CNN) είναι μια άλλη αναδυόμενη αρχιτεκτονική νευρικών δικτύων που εξελίσσεται από το πλήρως συνδεδεμένο τροφοδοτικό δίκτυο για να αποφευχθεί η ταχεία ανάπτυξη των παραμέτρων. Η βασική ιδέα του είναι η εισαγωγή συνελκτικών και ομαδοποιημένων στρωμάτων πριν από την τροφοδοσία εισόδου σε ένα πλήρως συνδεδεμένο δίκτυο. Κάθε νευρώνας στο συνελκτικό επίπεδο συνδέεται μόνο με μερικούς νευρώνες στο προηγούμενο παρακείμενο επίπεδο. Αυτοί οι νευρώνες είναι οργανωμένοι σε μορφή μήτρας για να αντιπροσωπεύουν χάρτες χαρακτηριστικών και οι νευρώνες στον ίδιο

χάρτη μοιράζονται τα ίδια βάρη. Στο επίπεδο συγκέντρωσης, οι νευρώνες στους χάρτες χαρακτηριστικών ομαδοποιούνται για να υπολογίσουν την μέση τιμή βάρους ή τη μέγιστη τιμή βάρους. Με αυτόν τον τρόπο, οι παράμετροι εκπαίδευσης μειώνονται σημαντικά πριν από τη χρήση πλήρως συνδεδεμένων δικτύων. Το κύριο πλεονέκτημα του συνελκτικού νευρικού δικτύου είναι η εκμάθηση των ιεραρχιών χαρακτηριστικών από μεγάλο αριθμό δεδομένων χωρίς σήμανση. Βελτιώνει το συμβατικό πολυεπίπεδο perceptron αξιοποιώντας τρεις τεχνικές, όπως κοινή χρήση παραμέτρων, ισοδύναμη αναπαράσταση και αραιές αλληλεπιδράσεις. Χάρη σε αυτές τις μοναδικές δυνατότητες, το συνελκτικό νευρικό δίκτυο δείχνει πολύ καλή απόδοση στις εφαρμογές επεξεργασίας απεικόνισης (David et al, 2019).

5.2.5 Επαναλαμβανόμενο νευρικό δίκτυο

Το επαναλαμβανόμενο νευρικό δίκτυο (Recurrent Neural Network - RNN) στοχεύει στην παροχή μνήμης στα νευρικά δίκτυα. Σε αντίθεση με τα συμβατικά δίκτυα τροφοδοσίας, η έξοδος του επαναλαμβανόμενου νευρικού δικτύου εξαρτάται τόσο από τους τρέχοντες υπολογισμούς όσο και από τους προηγούμενους υπολογισμούς. Κατ'αρχήν, μπορεί να επεξεργαστεί οποιοδήποτε μήκος δεδομένων ακολουθίας. Τα νετρόνια σε κρυφά επίπεδα συνδέονται έτσι ώστε τα κρυφά στρώματα να μπορούν να χρησιμοποιούν τις προηγούμενες εξόδους τους ως κύριες εισόδους για να επιτύχουν μνήμη. Η μέθοδος οπίσθιας διάδοσης χρησιμοποιείται συνήθως για την εκπαίδευση του μοντέλου δικτύου ενός επαναλαμβανόμενου νευρικού δικτύου. Ωστόσο, τα προβλήματα διαβάθμισης ή έκρηξης της κλίσης καθιστούν πολύ δύσκολη την εκπαίδευση του κανονικού επαναλαμβανόμενου νευρικού δικτύου. Για την αντιμετώπιση αυτών των ζητημάτων, τα μακροπρόθεσμα δίκτυα μνήμης βραχυπρόθεσμης μνήμης (long short term memory networks - LSTM) και GRU αναπτύχθηκαν τα τελευταία χρόνια. Τα επαναλαμβανόμενα νευρικά δίκτυα χρησιμοποιούνται συχνά για την αντιμετώπιση διαδοχικών ή προβλημάτων χρονοσειρών, όπως η επεξεργασία φυσικής γλώσσας (Viswanthan et al, 2020).

5.2.6 Γενετικό δίκτυο αντιπαραθέσεων

Το γενετικό δίκτυο αντιπαραθέσεων (Generative Adversarial Network - GAN) αναφέρεται σε ένα πλαίσιο που εκπαιδεύει τα μοντέλα δημιουργίας χρησιμοποιώντας μια διαδικασία αντιπαραθέσης. Το πλαίσιο αποτελείται από δύο μοντέλα: το γενετικό

μοντέλο χρησιμοποιείται για την προσέγγιση της κατανομής δεδομένων στόχου από δεδομένα εκπαίδευσης, το διακριτικό μοντέλο εκτιμά ότι η πιθανότητα των δεδομένων προέρχεται από πραγματικά δεδομένα εκπαίδευσης και όχι από την έξοδο του γενετικού μοντέλου. Η γεννήτρια και ο διαχωριστής εκπαιδεύονται επαναληπτικά. Ο στόχος της διαδικασίας εκπαίδευσης είναι να μεγιστοποιήσει την πιθανότητα λήψης λανθασμένης απόφασης από τον διακριτή. Επομένως, η γεννήτρια θα παράγει δεδομένα κοντά στην πραγματική διανομή δεδομένων. Η εκπαίδευση ενός συμβατικού γενετικού δικτύου αντιπαραθέσεων είναι πολύ δύσκολη επειδή είναι πολύ ευαίσθητη στη δομή του μοντέλου, στο ρυθμό εκμάθησης και στις ρυθμίσεις υπερπαραμέτρων (Saad et al, 2019).

5.2.7 Μάθηση βαθιάς ενίσχυσης

Αξιοποιώντας την ισχυρή ικανότητα αναπαράστασης δεδομένων του βαθιού νευρικού δικτύου, η μάθηση βαθιάς ενίσχυσης (DRL) αναδύεται και δείχνει πολλά υποσχόμενες δυνατότητες για την επίλυση πολύπλοκων προβλημάτων στα δυναμικά ραδιο περιβάλλοντα με μεγάλο χώρο δράσης. Η μάθηση βαθιάς ενίσχυσης αναφέρεται σε μεθόδους που προσεγγίζουν συναρτήσεις αξίας ή συναρτήσεις πολιτικής από το βαθύ νευρικό δίκτυο, γεγονός που καθιστά δυνατή την αντιμετώπιση προβλημάτων λήψης αποφάσεων με κατάσταση υψηλής διάστασης και μεγάλο χώρο δράσης. Η μάθηση βαθιάς ενίσχυσης βασίζεται στο βαθύ νευρικό δίκτυο για την προσέγγιση της καλύτερης πολιτικής. Οι τυπικές μέθοδοι περιλαμβάνουν Deep Q-δίκτυα, βαθιά διαβάθμιση πολιτικής. Αυτές οι μέθοδοι αποδεικνύουν καλή απόδοση στην αυτόνομη οδήγηση, τη ρομποτική και τα παιχνίδια. Ως ένα από τα πιο επιτυχημένα παραδείγματα μάθησης βαθιάς ενίσχυσης, το AlphaGo εξαρτάται από ένα βαθύ νευρικό δίκτυο εκπαιδευμένο χρησιμοποιώντας εποπτευόμενη μάθηση, μάθηση ενίσχυσης και συμβατικούς ευρετικούς αλγόριθμους. Πολλά ζητήματα δικτύου κινητής τηλεφωνίας μπορούν να διατυπωθούν ως διαδικασία απόφασης Markov, όπου η μάθηση βαθιάς ενίσχυσης μπορεί να χρησιμοποιηθεί για τη λήψη των βέλτιστων αποφάσεων μακροπρόθεσμα, όπως δρομολόγηση, έλεγχος παρακολούθησης του MIMO, ενεργοποίηση / απενεργοποίηση προσαρμοστικών κυψελών για εξοικονόμηση ενέργειας κ.λπ (Liu et al, 2020).

6 Ενισχυμένα με Τεχνητή Νοημοσύνη Δίκτυα

6.1 Advanced Wireless Interface

6.1.1 Εκτίμηση και ανίχνευση καναλιών

Καθώς προέκυψαν νέα σενάρια 6G, όπως μοριακές επικοινωνίες και νέες τεχνολογίες όπως UM-MIMO, mmWave, επικοινωνία THz, τα μελλοντικά κανάλια ραδιοεπικοινωνίας γίνονται πιο περίπλοκα. Επομένως, είναι πιο δύσκολο να εκτιμηθεί αποτελεσματικά η κατάσταση του καναλιού. Για να επιτευχθεί εκτίμηση καναλιών υψηλής ανάλυσης αναπτύχθηκε ένα πλαίσιο εκτίμησης καναλιού με βάση το βαθύ νευρικό δίκτυο για το σύστημα ορθογωνικής πολυπλεξίας διαίρεσης συχνότητας (orthogonal frequency-division multiplexing - OFDM). Μετά την εκπαίδευση του μοντέλου σε διαφορετικές συνθήκες καναλιού, η έξοδος που παράγεται από το βαθύ νευρικό δίκτυο μπορεί να ανακτήσει τα σύμβολα εισόδου χωρίς να απαιτείται ρητή ανίχνευση καναλιού. Τα αποτελέσματα προσομοίωσης δείχνουν ότι η μέθοδος ξεπερνά τις συμβατικές μεθόδους. Εκτός αυτού, το συνελκτικό νευρικό δίκτυο έχει ληφθεί υπόψη για την εκτίμηση καναλιών MIMO. Σχεδιάστηκε έναν ελαφρύ, κατά προσέγγιση εκτιμητή μέγιστης πιθανότητας αξιοποιώντας τη δομή του μοντέλου καναλιού MIMO, αποδεικνύεται ότι οι μέθοδοι που βασίζονται στο συνελκτικό νευρικό δίκτυο ξεπερνούν τους συμβατικούς εκτιμητές όσον αφορά την υπολογιστική πολυπλοκότητα. Επιπλέον, με βάση την εκτίμηση της κατεύθυνσης των αφίξεων και στα κανάλια εκτίμησης καναλιού μαζικής MIMO, προτείνεται μια προσέγγιση βασισμένη στο πλαίσιο βαθιού νευρικού δικτύου. Μετά την εκπαίδευση εκτός σύνδεσης του βαθιού νευρικού δικτύου, η προσέγγιση ξεπερνά άλλα σχήματα όσον αφορά το Bit Error Rate (BER). Εκτός αυτού, προτείνεται μια ενδιαφέρουσα ιδέα της χρήσης βαθιάς μάθησης για την εκτίμηση καναλιών του τεράστιου MIMO. Για να επιτευχθεί καλή απόδοση εκτίμησης καναλιού με χαμηλότερο εναέριο CSI, ένα πλαίσιο βαθιού νευρικού δικτύου αποτελείται από έναν κωδικοποιητή και προτείνεται ένας αποκωδικοποιητής. Ο κωδικοποιητής μετατρέπει τον φορέα σε λέξεις κώδικες με συμπύεση, και στη συνέχεια ο αποκωδικοποιητής ανακτά το CSI με βάση το συνελκτικό νευρικό δίκτυο και το RefineNet. Υποστηρίζεται ότι η μέθοδος επιτυγχάνει ανώτερη απόδοση εκτίμησης καναλιού με χαμηλή πολυπλοκότητα. Επιπλέον, δεδομένου ότι οι συμβατικές μέθοδοι επαναληπτικής ανίχνευσης οδηγούν σε αρνητικό αντίκτυπο στην εφαρμογή σε πραγματικό χρόνο, πολλοί ερευνητές

καταφεύγουν σε μεθόδους βαθιάς μάθησης για την ανίχνευση καναλιών, ξετυλίγοντας συγκεκριμένους αλγόριθμους επαναληπτικής ανίχνευσης. Αξιοποιώντας τις ευέλικτες δομές επιπέδων, η προσέγγιση ανίχνευσης με βάση τη βαθιά μάθηση μπορεί να κάνει την κατάλληλη ανταλλαγή μεταξύ της ακρίβειας ανίχνευσης και της υπολογιστικής πολυπλοκότητας. Έχει επίσης προταθεί ένας ανιχνευτής με βάση τη βαθιά μάθηση που ονομάζεται DetNet για την ανακατασκευή των μεταδιδόμενων σημάτων χρησιμοποιώντας το ληφθέν σήμα και τη μήτρα καναλιού ως εισόδους σε πολυεπίπεδη δομή και βελτιστοποίηση της μέγιστης πιθανότητας ξετυλίγοντας τον προβλεπόμενο αλγόριθμο καθόδου κλίσης. Τα αποτελέσματα προσομοίωσης δείχνουν ότι το DetNet επιτυγχάνει παρόμοια ακρίβεια με τους συμβατικούς αλγόριθμους με πολύ λιγότερο χρόνο. Επιπλέον, για την αντιμετώπιση των νέων σεναρίων χωρίς μαθηματικά ανιχνεύσιμα μοντέλα καναλιών, διερευνήθηκε η απόδοση διαφόρων μεθόδων βαθιάς μάθησης, συμπεριλαμβανομένων των πλήρως συνδεδεμένων συνελκτικών νευρικών δικτύων, βαθιών νευρικών δικτύων για ανίχνευση καναλιών σε μοριακή επικοινωνία. Τα αποτελέσματα της δοκιμής δείχνουν ότι αυτοί οι ανιχνευτές με βάση τη βαθιά μάθηση ξεπερνούν τον συμβατικό ανιχνευτή. Ειδικά, ο ανιχνευτής που βασίζεται στο LSTM δείχνει εξαιρετική απόδοση στα σενάρια μοριακής επικοινωνίας ακόμη και με παρεμβολές μεταξύ συμβόλων (Jameel et al, 2020).

6.1.2 Αναγνώριση διαμόρφωσης

Η αναγνώριση διαμόρφωσης στοχεύει στον εντοπισμό τύπων διαμόρφωσης των λαμβανόμενων σημάτων. Οι συμβατικές προσεγγίσεις περιλαμβάνουν διάφορες διαδικασίες όπως προεπεξεργασία, εξαγωγή χαρακτηριστικών και ταξινόμηση. Αξιοποιώντας τη μη γραμμική ικανότητα επεξεργασίας, την αυτοπροσαρμογή και την ευρωστία των μοντέλων μηχανικής μάθησης, πολλά έργα έχουν αφιερωθεί στη βελτίωση της ακρίβειας και της αποτελεσματικότητας της αναγνώρισης διαμόρφωσης. Για παράδειγμα, έχει προταθεί ένας ταξινομητής διαμόρφωσης που βασίζεται σε νευρικά δίκτυα για να διακρίνει διαμορφωμένα σήματα που έχουν υποστεί ζημιά από θόρυβο από διάφορα ψηφιακά και αναλογικά σχήματα διαμόρφωσης. Τα αποτελέσματα του πειράματος δείχνουν ότι η απόδοση εξαρτάται σε μεγάλο βαθμό από τα χειροκίνητα εξαγόμενα χαρακτηριστικά. Για να ξεπεραστεί η αδυναμία, οι προσεγγίσεις βαθιάς μάθησης θεωρήθηκαν ότι μαθαίνουν βασικά χαρακτηριστικά από μη επεξεργασμένα δεδομένα αυτόματα. Προτάθηκε μια μέθοδος που βασίζεται στο

συνελικτικό νευρικό δίκτυο για να μάθει τύπους διαμόρφωσης από δείγματα ακατέργαστων δεδομένων μέσω της διεπαφής ραδιοσυχνοτήτων. Τα αποτελέσματα των δοκιμών δείχνουν ότι η προσέγγιση που βασίζεται στο συνελικτικό νευρικό δίκτυο ξεπερνά δύο άλλες συμβατικές προσεγγίσεις και η απόδοση βελτιώνεται με αυξημένη αναλογία σήματος προς θόρυβο (Signal-to-Noise Ratio - SNR). Ωστόσο, η απόδοση δεν μπορεί να βελτιωθεί συνεχώς σε πολύ υψηλή αναλογία σήματος προς θόρυβο επειδή η βραχυπρόθεσμη φύση των δειγμάτων εκπαίδευσης μπερδεύει τον ταξινομητή. Για να ξεπεραστεί το ζήτημα, αναπτύχθηκε ένα πλαίσιο ταξινόμησης αυτόματης διαμόρφωσης βασισμένο σε βαθιά μάθηση, αξιοποιώντας τη δύναμη του LSTM. Μετά την εκπαίδευση του πλαισίου με 11 τυπικούς τύπους διαμόρφωσης, η υψηλή απόδοση αποδεικνύεται σε υψηλά περιβάλλοντα αναλογίας σήματος προς θόρυβο. Επιπλέον, διερευνήθηκε η απόδοση διαφορετικών αλγορίθμων βαθιάς μάθησης, συμπεριλαμβανομένων των παραδοσιακών συνελικτικών νευρικών δικτύων, ResNet, Inception CNN και LSTM στην αναγνώριση διαμόρφωσης. Τα αποτελέσματα της σύγκρισης υποδηλώνουν ότι το LSTM μπορεί να επιτύχει την υψηλότερη ακρίβεια στις περισσότερες περιπτώσεις. Τα υπάρχοντα έργα αποκαλύπτουν τη δυνατότητα της βαθιάς μάθησης στην αναγνώριση βασικών χαρακτηριστικών. Επομένως, αξίζει να γίνει εκμετάλλευσή της για την αναγνώριση άλλων παραμέτρων όπως κωδικοποίηση καναλιού, εξαγωγή CSI και εκμάθηση χαρακτηριστικών από σήματα (Wilhelmi et al, 2021).

6.1.3 Αποκωδικοποίηση καναλιού

Δεδομένου ότι είναι απλή η εφαρμογή νευρικού δικτύου στην αποκωδικοποίηση καναλιών, πολλοί αποκωδικοποιητές που βασίζονται σε μηχανική μάθηση έχουν προταθεί από τη δεκαετία του 1990. Σε αντίθεση με τους συμβατικούς αποκωδικοποιητές που βασίζονται στη θεωρία της πληροφορίας, οι αποκωδικοποιητές που βασίζονται στο νευρικό δίκτυο δεν βασίζονται σε ειδικές γνώσεις. Μετά τη διαδικασία εκπαίδευσης, η διαδικασία αποκωδικοποίησης είναι απλή και γρήγορη. Ωστόσο, ένα θεμελιώδες μειονέκτημα του αποκωδικοποιητή που βασίζεται στο νευρικό δίκτυο είναι η επεκτασιμότητα, επειδή η πολυπλοκότητα της εκπαίδευσης αυξάνεται εκθετικά με την αύξηση του μήκους του μπλοκ. Επομένως, τα πρόσφατα έργα στρέφονται σε βαθιά μάθηση για να αντιμετωπίσουν το ζήτημα της διαστατικότητας ξεδιπλώνοντας τη διαδραστική δομή σε πολυεπίπεδη δομή. πρότεινε

έναν αποκωδικοποιητή βασισμένο σε πλήρως συνδεδεμένο βαθύ νευρικό δίκτυο για τη βελτίωση της απόδοσης της διάδοσης πεποιθήσεων (Belief Propagation - BP) στην αποκωδικοποίηση κωδικών ελέγχου υψηλής πυκνότητας (high-density parity check - HDPC). Τα αποτελέσματα δείχνουν ότι ο αποκωδικοποιητής ξεπερνά τους συμβατικούς αλγόριθμους αποκωδικοποιητών διάδοσης πεποιθήσεων, αν και η απόδοση υποβαθμίζεται σε μεγάλους κωδικούς BCH. Προτείνεται ένας αποκωδικοποιητής διάδοσης πεποιθήσεων που βασίζεται στο συνελκτικό νευρικό δίκτυο τροφοδοτώντας την έξοδο των επιπέδων ισοτιμίας στην είσοδο μεταβλητών επιπέδων και ενοποιώντας τις παραμέτρους βάρους σε κάθε επανάληψη. Αναφέρεται ότι ο αποκωδικοποιητής BP-RNN ξεπερνά τον απλό αποκωδικοποιητή διάδοσης πεποιθήσεων. Εκτός αυτού, αναπτύχθηκε μια απλή αρχιτεκτονική βαθιού νευρικού δικτύου με βάση τον αποκωδικοποιητή για την αποκωδικοποίηση κωδικών λέξεων μήκους N με bit πληροφοριών K . Ο αποκωδικοποιητής λειτουργεί για πολικούς κωδικούς μήκους 16-bit και επιτυγχάνει μέγιστη εκ των υστέρων απόδοση. Ωστόσο, η απόδοση υποβαθμίζεται με την αυξανόμενη διάρκεια των πληροφοριών. Ευτυχώς, κατά την αποκωδικοποίηση δομημένων κωδικών, μπορεί να γενικεύσει ένα υποσύνολο κωδικών λέξεων για εκπαίδευση στην αποκωδικοποίηση αόρατων κωδικών λέξεων. Επιπλέον, η απόδοση του πολικού κώδικα μπορεί να βελτιωθεί με τη χρήση μεθόδων αποκωδικοποίησης με βάση βαθιά μάθηση. Συγκεκριμένα, η κύρια ιδέα είναι η αντικατάσταση υπο-μπλοκ του αποκωδικοποιητή από στοιχεία που βασίζονται στο νευρικό δίκτυο, η προκύπτουσα προσέγγιση αποκωδικοποίησης επιτρέπει ένα υψηλό επίπεδο παραλληλισμού και δείχνει μια ανταγωνιστική απόδοση ρυθμού σφάλματος bit (Bit Error Rate - BER). Οι υπάρχουσες μελέτες αποκαλύπτουν ότι η εφαρμογή βαθιάς μάθησης για να μάθει ένα αποκωδικοποιημένο δίκτυο δομημένης βάσης είναι πολλά υποσχόμενη (Khan et al, 2020).

6.1.4 Βελτιστοποίηση ασύρματου από άκρο σε άκρο

Παρόλο που έχουν χρησιμοποιηθεί προσεγγίσεις μηχανικής μάθησης για τη βελτίωση της απόδοσης ορισμένων μπλοκ επεξεργασίας της διεπαφής ραδιοσυχνότητας, το παγκόσμιο βέλτιστο σύστημα επικοινωνίας δεν μπορεί να διασφαλιστεί με τη βελτιστοποίηση κάθε μπλοκ ανεξάρτητα. Πρόσφατα, ορισμένοι ερευνητές επανεξετάζουν το σύστημα επικοινωνίας ως έργο ανασυγκρότησης από άκρο σε άκρο για τη βελτιστοποίηση της απόδοσης του συστήματος. Το πλαίσιο ΑΕ χρησιμοποιείται

για να αντιπροσωπεύσει ολόκληρο το σύστημα επικοινωνίας με τον πομπό, το δέκτη και το πρόσθετο κανάλι λευκού θορύβου Gauss. Η απόδοση του συστήματος βελτιστοποιείται από άκρο σε άκρο. Συγκεκριμένα, ο πομπός και ο δέκτης μοντελοποιούνται ως πλήρως συνδεδεμένοι στο βαθύ νευριό δίκτυο και το κανάλι λευκού θορύβου Gauss αντιπροσωπεύεται ως επίπεδο θορύβου. Επομένως, το σύστημα επικοινωνίας μπορεί να αναπαρασταθεί ως σύστημα αυτόματου κωδικοποιητή, το οποίο μπορεί να εκπαιδευτεί για τη βελτιστοποίηση της απόδοσης από άκρο σε άκρο, όπως ο ρυθμός σφάλματος bit. Τα αποτελέσματα προσομοίωσης δείχνουν ότι η προσέγγιση που βασίζεται στο ΑΕ μπορεί να επιτύχει καλύτερη απόδοση από το συμβατικό BPSK με κωδικό σφυρηλάτησης. Ομοίως, προτείνεται μια άλλη ασύρματη επικοινωνία βασισμένη σε ΑΕ, όπου τα δεδομένα εισόδου κωδικοποιούνται σε σήμα μέσω βαθιού νευρικού δικτύου στην πλευρά του πομπού και ο δέκτης αποκωδικοποιεί το ληφθέν σήμα μέσω του βαθιού νευρικού δικτύου. Σε άλλες δοκιμές, η προσέγγιση που βασίζεται στο ΑΕ επεκτείνεται στα κανάλια MIMO. Λαμβάνονται υπόψη τόσο τα συστήματα ανοιχτού βρόχου χωρίς ανατροφοδότηση CSI όσο και η ανατροφοδότηση κλειστού βρόχου με CSI. Το αποτέλεσμα προσομοίωσης ενός συστήματος MIMO 2 x 2 δείχνει ότι το πλαίσιο ΑΕ ξεπερνά τα συμβατικά σχήματα ανοιχτού βρόχου MIMO. Το MIMO ΑΕ με τέλειο CSI ξεπερνά τα συμβατικά σχήματα κωδικοποίησης στις περισσότερες αναλογίες σήματος προς θόρυβο. Το βαθύ νευρικό δίκτυο έχει επίσης χρησιμοποιηθεί για την προσέγγιση του μη ορθογώνιου συστήματος πολλαπλής πρόσβασης (non-orthogonal multiple access - NOMA) το οποίο θεωρείται ως μαύρο κουτί. Όλο το σύστημα NOMA διαμορφώνεται ως ΑΕ, όπου οι διαδικασίες κωδικοποίησης και αποκωδικοποίησης επεξεργάζονται από κοινού. Τα αποτελέσματα της προσομοίωσης δείχνουν ότι η προτεινόμενη λύση επιτυγχάνει χαμηλότερο ρυθμό σφάλματος bit από τις συμβατικές μεθόδους σκληρής απόφασης. Επιπλέον, προτείνεται ένα σύστημα επικοινωνίας από άκρο σε άκρο συνδυάζοντας βαθύ νευρικό δίκτυο και γενετικό δίκτυο αντιπαραθέσεων. Συγκεκριμένα, ένα σύστημα καναλιού-αγνωστικής μάθησης αναπτύσσεται με την εκμάθηση της εξόδου καναλιού επικοινωνίας μέσω ενός υπό όρους γενετικού δικτύου αντιπαραθέσεων. Τα αποτελέσματα δείχνουν ότι η μέθοδος είναι αποτελεσματική στα κανάλια εξασθένισης Rayleigh και στα πρόσθετα κανάλια λευκού θορύβου Gauss. Αυτές οι μελέτες ανοίγουν μια πιθανή ευκαιρία για τη δημιουργία συστημάτων επικοινωνίας 6G βάσει δεδομένων (Yang et al, 2020).

6.2 Έξυπνος Έλεγχος Κίνησης

6.2.1 Ταξινόμηση και πρόβλεψη κυκλοφορίας

Η ταξινόμηση της κυκλοφορίας στοχεύει στον εντοπισμό και την κατηγοριοποίηση συγκεκριμένων εφαρμογών ή πρωτοκόλλων από μεγάλο όγκο κυκλοφορίας που διέρχεται από δίκτυα. Είναι η βάση για άλλες σημαντικές εργασίες, όπως έλεγχος κυκλοφορίας, QoS και έλεγχος φόρτισης, κ.λπ. Με την αύξηση της κρυπτογραφημένης κίνησης στο δίκτυο κινητής τηλεφωνίας, οι συμβατικές προσεγγίσεις ταξινόμησης κίνησης βασισμένες σε έλεγχο πακέτων αντιμετωπίζουν μια μεγάλη πρόκληση. Πρόσφατα, πολλές προσπάθειες προσπαθούν να αξιοποιήσουν την προηγμένη προσέγγιση μηχανικής μάθησης για την ταξινόμηση και την πρόβλεψη της κυκλοφορίας. Έχει προταθεί μια μέθοδος αυτόματου κωδικοποιητή για τον προσδιορισμό των πρωτοκόλλων ανώτερου επιπέδου από ένα σύνολο δεδομένων κίνησης TCP, το αποτέλεσμα του πειράματος δείχνει ότι η μέθοδος μπορεί να επιτύχει καλή ακρίβεια και χαμηλούς ρυθμούς ανάκλησης. Για την ταξινόμηση της κρυπτογραφημένης κίνησης, προτάθηκε ένα μονοδιάστατο πλαίσιο βασισμένο στο συνελκτικό νευρικό δίκτυο, το οποίο μπορεί να μοντελοποιήσει διαδοχικά δεδομένα με χαμηλή πολυπλοκότητα. Στοχεύοντας σε ένα παρόμοιο πρόβλημα, προτάθηκε μια προσέγγιση που βασίζεται στο συνελκτικό νευρικό δίκτυο για την πραγματοποίηση της κρυπτογραφημένης ταξινόμησης. Η μέθοδος μπορεί να μειώσει σημαντικά την προσπάθεια της μηχανικής χαρακτηριστικών και να επιτύχει υψηλή ακρίβεια. Πρόσφατα, διερευνήθηκαν διάφορες μέθοδοι βαθιάς μάθησης όπως το πολυεπίπεδο perceptron, συνελκτικό νευρικό δίκτυο και LSTM σχετικά με την κρυπτογραφημένη ταξινόμηση δεδομένων κινητής τηλεφωνίας. Αποδεικνύεται ότι το βαθύ νευρικό δίκτυο μπορεί να εξαγάγει αυτόματα σύνθετα χαρακτηριστικά από μεγάλες ποσότητες κίνησης δεδομένων κινητής τηλεφωνίας. Τα αποτελέσματα του πειράματος αποκαλύπτουν ότι οι προσεγγίσεις με βάση τη βαθιά μάθηση ξεπερνούν τις μεθόδους μηχανικής μάθησης ως προς την ακρίβεια. Επιπλέον, οι τεχνικές μηχανικής μάθησης έχουν χρησιμοποιηθεί ευρέως για την πρόβλεψη της μελλοντικής κατανομής της κυκλοφορίας. Για να γίνουν κατανοητά τα μοτίβα ζήτησης κίνησης των δικτύων ασύρματου πλέγματος, εκτιμήθηκαν με ακρίβεια οι κατανομές κυκλοφορίας χρησιμοποιώντας DBN με μοντέλα Gauss. Προτάθηκε μια μέθοδος για τη μοντελοποίηση των χωρικών και χρονικών συσχετίσεων της κίνησης μέσω κινητού, συνδυάζοντας AE και LSTM. Συγκεκριμένα, το AE χρησιμοποιείται για την εξαγωγή

του χωρικού χαρακτηριστικού, τη μείωση της διάστασης και την εκπαίδευση του παραλληλισμού. Οι συμπιεσμένες αναπαραστάσεις που δημιουργούνται από ΑΕ επεξεργάζονται από το LSTM για να προβλέψουν μελλοντική ζήτηση κυκλοφορίας, τα αποτελέσματα του πειράματος δείχνουν ότι η μέθοδος ξεπερνά τις συμβατικές προσεγγίσεις. Επιπλέον, για να πραγματοποιήσει την πρόβλεψη κυκλοφορίας για κινητά σε μεγάλα χρονικά διαστήματα, αναπτύχθηκε ένα νευρικό δίκτυο χωροχρόνου για να καταγράψει χωροχρονικά χαρακτηριστικά της κίνησης από κινητά συνδυάζοντας LSTM και 3D συνελκτικά νευρικά δίκτυα. Συνδυάζοντας τις προβλέψεις με ιστορικά μέσα, επέκτειναν σημαντικά το χρονικό πλαίσιο αξιόπιστων προβλέψεων (Zhang et al, 2020).

Ομοίως, χρησιμοποιήθηκε το συνελκτικό νευρικό δίκτυο και το LSTM για να πραγματοποιηθεί πρόβλεψη κυκλοφορίας δεδομένων κινητής τηλεφωνίας. Χάρη στην αποτελεσματική ικανότητα εξαγωγής χωροχρονικών χαρακτηριστικών, η πρόταση ξεπερνά σημαντικά τις συμβατικές προσεγγίσεις όσον αφορά την ακρίβεια των προβλέψεων. Οι υπάρχουσες μελέτες αποκαλύπτουν ότι οι σύνθετοι χωροχρονικοί συσχετισμοί στο εσωτερικό της κίνησης στην κινητή τηλεφωνία μπορούν να μάθουν αποτελεσματικά από τα συνελκτικά νευρικά δίκτυα και τα επαναλαμβανόμενα νευρικά δίκτυα, τα οποία είναι καλά στη μοντελοποίηση χωρικής και χρονικής συσχετιζόμενης κίνησης δεδομένων. Το LSTM είναι μια αποτελεσματική προσέγγιση για την πρόβλεψη της ζήτησης κίνησης με βάση τις γνώσεις χωροχρονικών συσχετίσεων (Catak et al, 2021).

6.2.2 Προσωρινή αποθήκευση κίνησης

Η αυξανόμενη δημοτικότητα των βελτιωμένων κινητών ευρυζωνικών εφαρμογών όπως AR, VR, XR έχει ως αποτέλεσμα την εκθετική αύξηση της κίνησης δεδομένων κινητής τηλεφωνίας. Εν τω μεταξύ, ορισμένες εφαρμογές IoT που είναι κρίσιμες για την αποστολή, όπως αυτόνομα οχήματα, απαιτούν εξαιρετικά χαμηλή καθυστέρηση. Για την αντιμετώπιση αυτών των προκλήσεων, η κινητή υπολογιστική άκρου αναδύεται ως ένα νέο παράδειγμα. Ωστόσο, είναι πολύ δύσκολο να βρεθούν βέλτιστες στρατηγικές προσωρινής αποθήκευσης, όπως βελτιστοποιημένη τοποθέτηση προσωρινής μνήμης, ενημέρωση προσωρινής μνήμης και αναλυτικά στοιχεία δημοτικότητας περιεχομένου. Η βαθιά μάθηση μπορεί να διαδραματίσει σημαντικό ρόλο στο σχεδιασμό αποτελεσματικών μηχανισμών προσωρινής αποθήκευσης και

υπολογιστών. Για παράδειγμα, για να μεγιστοποιηθεί το κέρδος της προληπτικής προσωρινής αποθήκευσης στο πλαίσιο των δικτύων συσκευή προς συσκευή (Device-to-Device), χρησιμοποιήθηκε το K-μέσο για να συγκεντρώσει χρήστες και να καθορίσει το σύνολο των επιρροών χρηστών για την προσωρινή αποθήκευση τοπικού δημοφιλούς περιεχομένου. Έχει επίσης προταθεί μια λύση που βασίζεται στη μάθηση μεταφοράς για να μάθει ένα μοντέλο που μπορεί να αποθηκεύσει έξυπνα περιεχόμενο στο σταθμό βάσης (Base Station - BS). Εκτός αυτού, για τη βελτιστοποίηση της προσωρινής αποθήκευσης σε μικρά δίκτυα κυψελών χρησιμοποιήθηκε ένας αλγόριθμος συμπλέγματος για να ομαδοποιήσει χρήστες με παρόμοιες προτιμήσεις περιεχομένου, τότε η μάθηση ενίσχυσης εφαρμόζεται για τον σταθμό βάσης για τη βελτιστοποίηση των αποφάσεων προσωρινής αποθήκευσης. Ομοίως, αναπτύχθηκαν λύσεις βασισμένες σε βαθιά μάθηση ώστε ο σταθμός βάσης να μάθει μοτίβα αιτημάτων χρηστών και να λάβει βέλτιστες αποφάσεις προσωρινής αποθήκευσης και προτείνεται μια στρατηγική συνεργασίας για κοντινούς σταθμούς βάσης για την εξυπηρέτηση συλλογικών αιτημάτων χρήστη. Τα αποτελέσματα του πειράματος δείχνουν σημαντικά κέρδη όσον αφορά τη μείωση του λανθάνοντος χρόνου και την εξοικονόμηση επισκεψιμότητας. Επιπλέον, αναπτύχθηκε μια καταναμημένη λύση προσωρινής αποθήκευσης με βάση την μάθηση Q για τη βελτίωση της αποτελεσματικότητας της προσωρινής αποθήκευσης. Συγκεκριμένα, με βάση την προβλεπόμενη προτίμηση των χρηστών και τη δημοτικότητα του περιεχομένου, η προσέγγιση βαθιάς μάθησης Q χρησιμοποιείται για την εύρεση της βέλτιστης στρατηγικής προσωρινής αποθήκευσης. Τα αποτελέσματα της προσομοίωσης δείχνουν ότι η μέθοδος ξεπερνά τον υπάρχοντα αλγόριθμο όσον αφορά τον ρυθμό επίσκεψης της κρυφής μνήμης. Επιπλέον, για να αντιμετωπιστεί το πρόβλημα της κοινής τεχνολογίας και της προσωρινής αποθήκευσης στο Internet των Οχημάτων (IoV), αναπτύχθηκε μια έξυπνη προσέγγιση κατανομής πόρων χρησιμοποιώντας τη βαθιά μάθηση ενίσχυσης. Τα αριθμητικά αποτελέσματα επιβεβαιώνουν την αποτελεσματικότητα της προτεινόμενης λύσης. Στην ουσία, οι τεχνικές βαθιάς μάθησης μπορούν να βελτιώσουν την προσωρινή αποθήκευση από πολλές απόψεις. Πρώτον, μπορούν να χρησιμοποιηθούν για την πρόβλεψη της διανομής και της συχνότητας των αιτημάτων περιεχομένου των χρηστών και του μοτίβου κινητικότητας, το οποίο μπορεί να χρησιμοποιηθεί για τη βελτιστοποίηση της πολιτικής αποθήκευσης και αντικατάστασης περιεχομένων της προσωρινής μνήμης. Επιπλέον, μπορούν να χρησιμοποιηθούν για να μάθουν τα ενδιαφέροντα, τις δραστηριότητες και τις αλληλεπιδράσεις των χρηστών, τα οποία μπορούν να

βοηθήσουν στη βελτίωση της ακρίβειας των προβλέψεων για μελλοντικές συμπεριφορές χρηστών. Επιπλέον, μπορούν να χρησιμοποιηθούν για την ταξινόμηση των χρηστών με βάση τις δραστηριότητές τους, κάτι που είναι πολύτιμο για να προσδιοριστεί ποιο περιεχόμενο θα αποθηκευτεί. Εν τω μεταξύ, ο συνδυασμός βαθιάς μάθησης με φορητή κρυφή μνήμη αντιμετωπίζει πολλές προκλήσεις. Η επεξεργασία δεδομένων πρέπει να είναι σε θέση να εξαγάγει χρήσιμα δεδομένα από μεγάλη ποσότητα περιεχομένου σε διαφορετικές μορφές για την εκπαίδευση μοντέλων βαθιών νευρικών δικτύων (Bhat et al, 2021).

6.2.3 Έξυπνη δρομολόγηση

Για την εκπλήρωση διαφορετικών απαιτήσεων QoS εφαρμογών 6G χρησιμοποιώντας αποτελεσματικά περιορισμένους πόρους δικτύου, έχουν αναπτυχθεί πολλοί ευρετικοί αλγόριθμοι για τη βελτιστοποίηση της απόδοσης δρομολόγησης με πολύπλοκους περιορισμούς. Το κύριο μειονέκτημα των ευρετικών αλγορίθμων είναι η υπολογιστική πολυπλοκότητα. Πρόσφατα, ορισμένοι ερευνητές έχουν χρησιμοποιήσει την προσέγγιση της μηχανικής μάθησης για την επίλυση προβλημάτων δρομολόγησης. Οι αλγόριθμοι δρομολόγησης που βασίζονται σε μηχανική μάθηση μπορούν να λαμβάνουν σχεδόν βέλτιστες αποφάσεις δρομολόγησης αμέσως μόλις εκπαιδευτούν. Επιπλέον, οι αλγόριθμοι μηχανικής μάθησης δεν εξαρτώνται από ένα ακριβές μοντέλο μαθηματικού δικτύου, το οποίο το καθιστά ελκυστικό για σύνθετα σενάρια δικτύου 6G. Από τη βιβλιογραφία, μπορεί να βρεθεί ότι η εποπτευόμενη μάθηση και η μάθηση ενίσχυσης θεωρούνται συνήθως στη βελτιστοποίηση δρομολόγησης. Σε αλγόριθμους με εποπτευόμενη μάθηση, το δίκτυο και η κατάσταση κυκλοφορίας χρησιμοποιούνται συχνά ως είσοδος και η έξοδος είναι η απόφαση δρομολόγησης του ευρετικού αλγορίθμου. Για παράδειγμα, προτάθηκε ένα πλαίσιο δρομολόγησης με ένα μετα-επίπεδο που βασίζεται σε μηχανική μάθηση, το οποίο χρησιμοποιεί την είσοδο και την έξοδο του ευρετικού αλγορίθμου ως σύνολο δεδομένων εκπαίδευσης. Το αποτέλεσμα του πειράματος δείχνει ότι η προσέγγιση μπορεί να επιτύχει ευρετική απόδοση σε πραγματικό χρόνο. Επιπλέον, προτάθηκε ένας δυναμικός μηχανισμός δρομολόγησης που ονομάζεται NeuRoute. Συγκεκριμένα, το LSTM χρησιμοποιείται για την πρόβλεψη μελλοντικών απαιτήσεων κίνησης δικτύου. Οι καταστάσεις δικτύου και οι προβλεπόμενες απαιτήσεις κυκλοφορίας χρησιμοποιούνται ως είσοδος και οι αποφάσεις δρομολόγησης από ευρετικούς αλγόριθμους χρησιμοποιούνται ως έξοδος

για την εκπαίδευση ενός μοντέλου νευρικού δικτύου. Ο μηχανισμός δρομολόγησης μπορεί να επιτύχει αποτελέσματα συγκρίσιμα με τον ευρετικό αλγόριθμο σε πραγματικό χρόνο μετά την εκπαίδευση. Παρόλο που οι λύσεις δρομολόγησης με εποπτευόμενη μάθηση μπορούν να επιτύχουν απόδοση συγκρίσιμη με ευρετικούς αλγόριθμους σε πραγματικό χρόνο, η παραγωγή ενός μεγάλου όγκου σημάνσεων εκπαιδευτικού συνόλου δεδομένων οδηγεί σε υψηλή υπολογιστική πολυπλοκότητα. Ως εναλλακτική προσέγγιση, η μάθηση ενίσχυσης μπορεί να χρησιμοποιηθεί για τη βελτιστοποίηση της δρομολόγησης. Έχει αναπτυχθεί ένας μηχανισμός δρομολόγησης βασισμένος σε μάθηση ενίσχυσης για δικτύωση καθορισμένη από λογισμικό. Ο μηχανισμός μπορεί να επιλέξει σχεδόν βέλτιστες διαδρομές δρομολόγησης βάσει της δυναμικής κατάστασης δικτύου. Παρομοίως, προτάθηκε ένας λογικά συγκεντρωτικός μηχανισμός δρομολόγησης χρησιμοποιώντας το τυχαίο νευρικό δίκτυο και μάθηση ενίσχυσης για το δίκτυο επικάλυψης κέντρου δεδομένων που βασίζεται σε δικτύωση καθορισμένη από λογισμικό, τα αποτελέσματα του πειράματος δείχνουν ότι ο μηχανισμός λειτουργεί καλά ακόμη και σε πολύ δυναμικά περιβάλλοντα. Επιπλέον, για την κάλυψη διαφορετικών απαιτήσεων QoS διαφορετικών εφαρμογών, προτάθηκε ένας μηχανισμός δρομολόγησης με γνώμονα το QoS για το δίκτυο καθορισμένη από λογισμικό, αξιοποιώντας τη μάθηση ενίσχυσης. Συγκεκριμένα, χρησιμοποιώντας το μέγιστο QoS ως ανταμοιβή, ο μηχανισμός δρομολόγησης που βασίζεται σε μάθηση ενίσχυσης μπορεί να επιλέξει την καλύτερη διαδρομή σύμφωνα με τους τύπους κυκλοφορίας και τις απαιτήσεις του χρήστη. Ομοίως, αναπτύχθηκε μια λύση δρομολόγησης βασισμένη σε βαθιά μάθηση ενίσχυσης για να ελαχιστοποιήσει την καθυστέρηση δικτύου από άκρο σε άκρο. Πρόσφατα, προτάθηκε ένας έξυπνος μηχανισμός επιλογής επόμενου κόμβου δρομολόγησης και αναπτύχθηκε ένας δρομολογητής που καθορίζεται από λογισμικό. Συνδυάζοντας τη στρατηγική πρώτης δρομολόγησης ανοικτής συντομότερης διαδρομής, οι προτεινόμενες μέθοδοι μπορούν να επιτύχουν υψηλότερη απόδοση με πολύ λιγότερα γενικά σήματα. Σε γενικές γραμμές, στο πλαίσιο μάθησης ενίσχυσης, ο ελεγκτής δικτύωσης καθορισμένης από λογισμικό ή ο δρομολογητής ενεργεί ως πράκτορας και το σύστημα δικτύου είναι το περιβάλλον, το οποίο περιέχει διαφορετικές καταστάσεις δικτύου και κυκλοφορίας. Η δράση είναι η απόφαση δρομολόγησης σε κάθε hop. Μπορούν να καθοριστούν διάφορες ανταμοιβές με βάση στόχους βελτιστοποίησης όπως καθυστέρηση, χρήση συνδέσμου, συμφόρηση κ.λπ. (Guo, 2020)

Πίνακας 1 Μια σύνοψη των μεγάλων έργων σχετικά με το σχεδιασμό ραδιοεπαφών με βάση ML / DL.

Τομέας	πρόβλημα / στόχος	Μοντέλο	Εκμάθηση Παραδείγματος	Κύρια συνεισφορά
Ανίχνευση εκτίμησης καναλιού	Εκτίμηση καναλιού για σύστημα OFDM	DNN	Supervised	Εξασφαλίστε καλύτερη απόδοση με λιγότερα γενικά έξοδα
	Ελαφρύς εκτιμητής καναλιών	CNN	Supervised	Υπερβαίνει τους υπάρχοντες εκτιμητές με χαμηλή πολυπλοκότητα
	Εκτίμηση καναλιού M-MIMO	DL	Supervised	Πραγματοποιήστε την εκτίμηση καναλιού με χαμηλό BER
	Ανίχνευση καναλιού	CNN	Unsupervised	Επιτυγχάνει παρόμοια ακρίβεια ανίχνευσης με λιγότερο χρόνο
	Ανίχνευση χωρίς μοντέλα	RNN	Unsupervised	Υπερβαίνει τους συμβατικούς ανιχνευτές καναλιών
	Διακριτικά σήματα αλλοιωμένα από θόρυβο	NN	Supervised	Προτείνετε έναν ταξινομητή διαμόρφωσης βάσει NN

6.3 Διαχείριση και Ενορχήστρωση Δικτύου

6.3.1 Διαχείριση ασύρματων πόρων

Παραδοσιακά, τα προβλήματα προγραμματισμού ασύρματων πόρων επιλύονται με βελτιστοποιήσεις, ευρετικές και βασισμένες σε θεωρητικές προσεγγίσεις παιχνιδιών. Ωστόσο, τα δίκτυα που εξελίσσονται προς το 6G γίνονται όλο και πιο περίπλοκα, είναι πολύ δύσκολο να διαμορφωθεί ένα ακριβές μαθηματικό μοντέλο και να επιλυθεί το πρόβλημα μεγάλης κλίμακας για να επιτευχθούν παγκόσμια βέλτιστα αποτελέσματα σε σύντομο χρονικό διάστημα. Επομένως, η μηχανική μάθηση διερευνάται ως εναλλακτική λύση. Έχει προταθεί ένα πλαίσιο διαχείρισης πόρων ραδιοεπικοινωνιών βασισμένο στη μάθηση ενίσχυσης. Το πλαίσιο περιλαμβάνει έναν συγκεντρωτικό εκπαιδευόμενο που λαμβάνει αποφάσεις βάσει αναφερόμενων πληροφοριών από καταναμημένους φορείς που συλλέγουν έμπειρες πληροφορίες από το δίκτυο και επιβάλλουν τις πολιτικές που έχουν μάθει από τον εκπαιδευόμενο. Για να μειωθεί η καθυστέρηση πακέτου και ο ρυθμός πτώσης πακέτων, προτείνεται μια προσέγγιση για τη βελτιστοποίηση του προγραμματισμού πόρων με βάση μάθηση ενίσχυσης σε συνδυασμό με το νευρικό δίκτυο και αξιολογήθηκε η απόδοση πέντε διαφορετικών αλγορίθμων μάθησης ενίσχυσης με διαφορετικές παραμέτρους, κατηγορίες κυκλοφορίας και στόχους βελτιστοποίησης. Πρόσφατα, για να επιλυθεί το απαιτητικό ζήτημα του προγραμματισμού πόρων στο τεμαχισμό του δικτύου ασύρματης πρόσβασης προτάθηκε μια έξυπνη προσέγγιση προγραμματισμού πόρων βασισμένη σε ένα συνεργατικό πλαίσιο μάθησης που συνδυάζει το βαθιά μάθηση με μάθηση ενίσχυσης. Συγκεκριμένα, η βαθιά μάθηση χρησιμοποιείται για την εκτέλεση κατανομής πόρων εκτός σύνδεσης σε μεγάλη χρονική κλίμακα και η μάθηση ενίσχυσης χρησιμοποιείται για την εκτέλεση διαδικτυακού προγραμματισμού πόρων σε μικρή χρονική κλίμακα. Επιπλέον, για να επιτευχθεί η βέλτιστη κατανομή πόρων σε υπερ-πυκνά δίκτυα, προτείνεται μια συνεργατική μέθοδος βαθιά Q-μάθησης για την εκτέλεση της σύνδεσης χρήστη-κυττάρων. Τα μικρά κελιά που επιλέγονται από χρήστες και τοπικές πληροφορίες χρησιμοποιούνται ως είσοδος στο νευρικό δίκτυο. Η έξοδος είναι οι εκτιμώμενες τιμές Q, οι οποίες μπορούν να χρησιμοποιηθούν από τους χρήστες για να επιλέξουν ένα μικρό κελί. Επιπλέον, οι καταναμημένες συσκευές αποτελούν μεγάλη πρόκληση για τη διαχείριση πόρων μελλοντικών δικτύων με επικοινωνία D2D. Για το σκοπό αυτό, εφαρμόζεται μάθηση ενίσχυσης που βασίζεται στο δίκτυο Bayes για τη μεγιστοποίηση της απόδοσης του συστήματος των δικτύων

D2D που υπόκεινται στους περιορισμούς ισχύος των συσκευών. Οι συσκευές δημιουργούν συνασπισμούς λαμβάνοντας υπόψη την επιλογή βάσης, την ισχύ μετάδοσης και τον τρόπο μετάδοσης για να μεγιστοποιήσουν τις μακροπρόθεσμες ανταμοιβές. Επιπλέον, με βάση τα ζητήματα κατανομής πόρων στο απτό Διαδίκτυο, προτάθηκε ένας αλγόριθμος Q-μάθησης για τη μεγιστοποίηση της απόδοσης χρηστών που απαιτούν υψηλή ένταση δεδομένων μέσω στρατηγικού προγραμματισμού αποκλεισμού πόρων. Με την εκμάθηση των προτύπων κυκλοφορίας και των συνθηκών καναλιού του δικτύου, το πλαίσιο Q-μάθησης μπορεί να βελτιστοποιήσει την καθυστέρηση και την απόδοση των χρηστών που απαιτούν ένταση δεδομένων με έξυπνη κατανομή πόρων (Lu & Ning, 2020).

6.3.2 Διαχείριση QoS και QoE

Καθώς το 6G αναμένεται να υποστηρίξει διάφορες εφαρμογές IoE, είναι πιο δύσκολο να διαχειριστούν τις διαφορετικές απαιτήσεις QoS από διαφορετικές εφαρμογές και να διασφαλιστεί το QoE διαφορετικών χρηστών. Η αποτελεσματική διαχείριση QoS και QoE είναι κρίσιμης σημασίας για τον χειριστή του δικτύου για τη βελτίωση της ικανοποίησης των χρηστών και τη μείωση της αλλαγής πελατών. Οι παράμετροι QoS σχετίζονται στενά με τον βασικό δείκτη απόδοσης (Key Performance Indicator - KPI) δικτύων όπως το ρυθμό μετάδοσης, μήκος ουράς, κ.λπ. Η επίτευξη των πολύπλοκων ποσοτικών συσχετίσεων μεταξύ παραμέτρων QoS και βασικού δείκτη απόδοσης είναι κρίσιμη για τη διαχείριση του QoS. Για το σκοπό αυτό, προτάθηκε μια προσέγγιση εκτίμησης καθυστέρησης χρησιμοποιώντας νευρικά δίκτυα. Το φορτίο κίνησης και η πολιτική δρομολόγησης χρησιμοποιούνται ως είσοδος και η καθυστέρηση δικτύου χρησιμοποιείται ως αποτέλεσμα της εποπτευόμενης μαθησιακής προσέγγισης. Τα αποτελέσματα του πειράματος δείχνουν ότι ο εκτιμητής με βάση το νευρικό δίκτυο ξεπερνά το συμβατικό μοντέλο M/M/1 όσον αφορά την ακρίβεια της εκτίμησης. Ομοίως, έγιναν προσπάθειες να ανακαλυφθούν οι σχέσεις χαρτογράφησης μεταξύ των παραμέτρων QoS και των μετρήσεων βασικού δείκτη απόδοσης χρησιμοποιώντας το δέντρο αποφάσεων. Ο αλγόριθμος γραμμικής παλινδρόμησης M5Rules χρησιμοποιείται για να ανακαλύψει τον ποσοτικό αντίκτυπο του βασικού δείκτη απόδοσης στο QoS. Το QoE είναι μια υποκειμενική μέτρηση για την ποσοτικοποίηση της ικανοποίησης των χρήσεων σε μια συγκεκριμένη υπηρεσία. Είναι πολύ χρονοβόρο για να ληφθούν οι τιμές QoE. Επομένως, η κατανόηση του τρόπου με τον οποίο οι

διάφορες παράμετροι QoS επηρεάζουν τις τιμές QoE είναι ιδιαίτερα σημαντική για την γρήγορη εξαγωγή της τιμής QoE (Piran & Sun, 2019).

Ο στόχος είναι η εκτίμηση του QoE της υπηρεσίας ροής βίντεο με μια εποπτευόμενη μαθησιακή προσέγγιση. Οι παράμετροι δικτύου που περιλαμβάνουν χρόνο μετ'επιστροφής (RTT), jitter, εύρος ζώνης και καθυστέρηση χρησιμοποιούνται ως είσοδος και το QoE χρησιμοποιείται ως έξοδος για την εκπαίδευση του μοντέλου νευρικού δικτύου. Με βάση το εκτιμώμενο QoE, ο ελεγκτής δικτύου το οποίο ορίζεται από το λογισμικό μπορεί να συντονίσει παραμέτρους δικτύου για να βελτιώσει το QoE. Ομοίως, έγιναν προσπάθειες να εκτιμηθούν οι τιμές QoE από τις παραμέτρους ποιότητας βίντεο. Εξετάστηκαν τέσσερις αλγόριθμοι μηχανικής μάθησης, όπως το δέντρο αποφάσεων, το νευρικό δίκτυο, το K-νευρικό δίκτυο και το τυχαίο δάσος. Επιπλέον, διερευνήθηκε η σχέση μεταξύ των παραμέτρων QoE και QoS για την πρόβλεψη του QoE του χρήστη με βάση παραμέτρους όπως διεκπεραίωση χρήστη, αριθμό ενεργών χρηστών, δείκτες ποιότητας καναλιού χρησιμοποιώντας πολυεπίπεδο perceptron. Τα αποτελέσματα προσομοίωσης δείχνουν υψηλή ακρίβεια πρόβλεψης. Με την εισαγωγή νέων εφαρμογών όπως η XR σε 6G, οι νέες μετρήσεις αξιολόγησης QoE και QoS καθιστούν πιο δύσκολη τη διαχείριση των QoE και QoS, τα υπάρχοντα έργα αποκαλύπτουν ότι η βαθιά μάθηση υπόσχεται να μάθει τις πολύπλοκες σχέσεις μεταξύ τους για να επιτύχει πιο αποτελεσματική ασφάλιση QoE και εκμετάλλευση πόρων (Pelthonen et al, 2020).

6.4 Βελτιστοποίηση Δικτύου

Για μελλοντικά δίκτυα 6G, η κάλυψη και η βελτιστοποίηση χωρητικότητας είναι ζωτικής σημασίας για την παροχή καθολικών υπηρεσιών δικτύου σε διάφορες περιπτώσεις χρήσης. Οι συμβατικές προσεγγίσεις βελτιστοποίησης, όπως γραμμικός ή μη γραμμικός προγραμματισμός, δυναμικός προγραμματισμός, ευρετικός αλγόριθμος, θεωρία παιχνιδιών δεν επαρκούν για τη διαχείριση σεναρίων μεγάλης κλίμακας και δυναμικών δικτύων 6G. Ως εκ τούτου, πολλοί ερευνητές έχουν στραφεί σε τεχνικές μηχανικής μάθησης για πιο αποτελεσματικές και έξυπνες λύσεις. Για να επιτευχθεί η βέλτιστη κάλυψη ρυθμίζοντας το μέγεθος του συμπλέγματος και τις παραμέτρους της κεραίας, προτάθηκε μια προσέγγιση δύο επιπέδων βασισμένη στους αυτό-οργανωμένους χάρτες. Συγκεκριμένα, χρησιμοποιούνται δύο αλγόριθμοι αυτό-οργανωμένων χαρτών για την πραγματοποίηση βελτιστοποίησης συμπλέγματος χωρίς

και με συντονισμό παραμέτρων κεραίας ταυτόχρονα. Τα αποτελέσματα δείχνουν το κέρδος 5% μόνο για βελτιστοποίηση συμπλέγματος και 13% για βελτιστοποίηση παραμέτρων συμπλέγματος και κεραίας. Έχει αναπτυχθεί ένα πλαίσιο μάθησης ενίσχυσης για να επιτύχει την κάλυψη και τη βελτιστοποίηση χωρητικότητας ρυθμίζοντας τη γωνία κλίσης των κεραιών. Για να πραγματοποιηθεί μια πλήρως αυτόνομη διαδικασία βελτιστοποίησης, διερευνήθηκαν διαφορετικές στρατηγικές μάθησης με βάση τη Fuzzy Q-μάθηση και προτάθηκε μια στρατηγική βασισμένη σε συμπλέγματα. Ομοίως, προτάθηκε μια ασαφής προσέγγιση μάθησης ενίσχυσης για τη βελτιστοποίηση της κάλυψης των δικτύων LTE. Τα αποτελέσματα προσομοίωσης επιβεβαιώνουν ότι η λύση μπορεί να συγκλίνει σε παγκόσμιες βέλτιστες ρυθμίσεις. Εκτός αυτού, για να μετριαστεί η παρεμβολή από μικροκύτταρα σε μακροκύτταρα σε αυτο-οργανωμένα δίκτυα μικροκυττάρων, το πρόβλημα διαιρέθηκε σε ζήτημα βελτιστοποίησης φορέα και ζήτημα βελτιστοποίησης ισχύος. Το πρώτο επιλύεται με μια μέθοδο Q-μάθησης. Η έρευνα δείχνει ότι η προσέγγιση μπορεί να βελτιστοποιήσει τη ρύθμιση των μικροκυττάρων και να μετριάσει την παρεμβολή τους στα μακροκύτταρα. Επιπλέον, με βάση το ζήτημα του συντονισμού των διακυτταρικών συμπερασμάτων στην κατώτερη σύνδεση του συστήματος LTE, διαπιστώθηκε ως συνεργατικό πρόβλημα ελέγχου πολλαπλών παραγόντων και για το βέλτιστο αποτέλεσμα θα πρέπει να εφαρμοστεί το πλαίσιο Q-μάθησης, όπου η κατάσταση ορίζεται από τη μετάδοση ισχύος, τη φασματική απόδοση, οι ενέργειες περιλαμβάνουν έλεγχο ισχύος και ορίζεται η μέση απόδοση ως ανταμοιβές (Lu & Zheng, 2020).

6.5 Ασφάλεια Δικτύου

Με την έξαρση νέων επιθέσεων, τα δίκτυα 6G θα αντιμετωπίσουν διάφορες νέες προκλήσεις και απειλές για την ασφάλεια. Συνήθως, τα συστήματα ασφαλείας δικτύου θα πρέπει τουλάχιστον να περιλαμβάνουν τείχη προστασίας, συστήματα εντοπισμού εισβολών (Intrusion Detection Systems - IDS) και λειτουργίες προστασίας από ιούς. Το σύστημα εντοπισμού εισβολών μπορεί να χρησιμοποιηθεί για τον εντοπισμό μη εξουσιοδοτημένης πρόσβασης, κακόβουλων συμπεριφορών όπως καταστροφή, τροποποίηση κ.λπ. Τρεις τύποι προσέγγισης ανάλυσης μπορούν να χρησιμοποιηθούν για την υλοποίηση του συστήματος εντοπισμού εισβολών: βασισμένη σε ανωμαλίες, βασισμένη στην υπογραφή και υβριδική. Οι τεχνικές βάσει υπογραφής προσδιορίζουν πιθανές επιθέσεις χρησιμοποιώντας υπογραφές αυτών των επιθέσεων. Είναι

αποτελεσματικές μόνο στον εντοπισμό επιθέσεων με γνωστές υπογραφές. Επομένως, απαιτούνται συχνές ενημερώσεις της βάσης δεδομένων υπογραφών επιθέσεων, γεγονός που καθιστά αδύνατη την ανίχνευση νέων επιθέσεων. Οι προσεγγίσεις που βασίζονται σε ανωμαλίες δημιουργούν τη βάση δεδομένων γνώσεων σχετικά με τη φυσιολογική συμπεριφορά δικτύου και συστήματος και, στη συνέχεια, προσδιορίζουν τις αποκλίσεις από την κανονική συμπεριφορά ως ανωμαλίες. Τα δεδομένα της μη φυσιολογικής συμπεριφοράς μπορούν να χρησιμοποιηθούν για την ανάπτυξη υπογραφών για την προσέγγιση βάσει υπογραφής. Το κύριο μειονέκτημα της προσέγγισης αυτής είναι το πιθανώς υψηλό ποσοστό λάθους συναγερμού λόγω άγνωστης νόμιμης συμπεριφοράς του συστήματος. Η υβριδική προσέγγιση συνδυάζει την ανίχνευση υπογραφών και ανωμαλιών για τη βελτίωση του ρυθμού εισβολών και τη μείωση του ψευδοθετικού ρυθμού άγνωστων επιθέσεων. Τα υπάρχοντα συστήματα εντοπισμού εισβολών αναπτύσσονται συνήθως ξεχωριστά σε ορισμένες περιοχές, γεγονός που κάνει δύσκολη τη συνεργασία τους. Για να ξεπεραστεί ο περιορισμός των συμβατικών συστημάτων εντοπισμού εισβολών, οι τεχνικές μηχανικής μάθησης έχουν χρησιμοποιηθεί ευρέως σε σύγχρονα συστήματα ασφαλείας δικτύου για ανίχνευση εισβολής (Jiang et al, 2021).

7 Βιομηχανική τυποποίηση και έργα

7.1 Πρωτοβουλίες τυποποίησης

7.1.1 3GPP

Το 3GPP ξεκίνησε τη μεγάλη ευφυΐα δικτύου βάσει δεδομένων από το σύστημα 5G. Τον Ιανουάριο του 2018, η 3GPP SA WG2 ενέκρινε τη μελέτη των ενεργοποιητών για αυτοματοποίηση δικτύου της 5G. Ο στόχος ήταν να μελετηθούν τα απαραίτητα δεδομένα που εκτίθενται στην ανάλυση δεδομένων δικτύου και η απαραίτητη έξοδος για την υποστήριξη των ακόλουθων περιπτώσεων χρήσης: 1) Προσαρμοσμένη διαχείριση κινητικότητας σε επίπεδο UE. 2) Επαλήθευση διασφάλισης QoS και δημιουργία μη τυποποιημένων προφίλ QoS. 3) Δυναμική καθοδήγηση κίνησης και διαίρεση, καθοδήγηση κίνησης με βάση τη συμπεριφορά των χρηστών. 4) Διαχείριση πόρων με βάση την ταξινόμηση της κυκλοφορίας. Ως αποτέλεσμα της μελέτης, η λειτουργία ανάλυσης δεδομένων δικτύου (network data analytics function - NWDAF) εισήχθη επίσημα στην αρχιτεκτονική δικτύου 5G στο R16. Η λειτουργία ανάλυσης δεδομένων δικτύου αντιπροσωπεύει μια λογική συνάρτηση αναλυτικών στοιχείων δικτύου. Μπορεί να συλλέξει δεδομένα περιβάλλοντος χρήστη και δικτύου από σχετικές λειτουργίες δικτύου και παρέχει αποτελέσματα ανάλυσης σε άλλες λειτουργίες δικτύου. Για παράδειγμα, παρέχει ανάλυση δεδομένων σε επίπεδο slice δικτύου στη λειτουργία ελέγχου πολιτικής (Policy Control Function - PCF) για έξυπνη δημιουργία πολιτικής και βοηθά τη λειτουργία επιλογής slice δικτύου για έξυπνη επιλογή slice (Monserat et al, 2020).

7.1.2 ITU

Τον Νοέμβριο του 2017, η ομάδα μελέτης ITU 13 ίδρυσε την ομάδα εστίασης στη μηχανική μάθηση για το μελλοντικό δίκτυο, συμπεριλαμβανομένου του 5G (FG-ML5G). Ο στόχος ήταν να εντοπιστεί το κενό τυποποίησης για τη βελτίωση της διαλειτουργικότητας, της αξιοπιστίας και της αρθρωτότητας της μεθόδου μηχανικής μάθησης 5G. Η ομάδα είχε ως στόχο τη δημιουργία εκθέσεων μελέτης και προδιαγραφών σχετικά με την αρχιτεκτονική του δικτύου, τα πρωτόκολλα, τις διεπαφές, τους αλγόριθμους και τις μορφές δεδομένων για την υιοθέτηση της μηχανικής μάθησης σε 5G και μελλοντικά δίκτυα. Έχει δημιουργήσει τρεις υπο-

ομάδες: 1) Η πρώτη είναι υπεύθυνη για περιπτώσεις χρήσης, υπηρεσίες και απαιτήσεις. 2) Η δεύτερη εστιάζει στη μορφή δεδομένων και στις τεχνικές μηχανικής μάθησης. 3) Η τρίτη είναι υπεύθυνη για την αρχιτεκτονική δικτύου μηχανικής μάθησης. Μετά την πρώτη μελέτη, η ομάδα δημοσίευσε τεχνικές προδιαγραφές για την αρχιτεκτονική για μηχανική μάθηση σε 5G και μελλοντικά δίκτυα στις αρχές του 2019 (Nayak et al, 2021).

7.1.3 ETSI

Για να βελτιώσει την εμπειρία διαχείρισης δικτύου, το ETSI δημιούργησε μια ομάδα βιομηχανικών προδιαγραφών (Industrial Specification Group - ISG) που ονομάστηκε βιομηχανική νοημοσύνη δικτύου (BAΔ) τον Φεβρουάριο του 2017. Ο στόχος είναι να καθοριστεί ένα γνωστικό πλαίσιο διαχείρισης δικτύου βάσει του μοντέλου ελέγχου του «παρατήρηση-προσανατολισμός-απόφαση-δράση». Η βασική ιδέα του BAΔ είναι η ευαισθητοποίηση σχετικά με το περιβάλλον δικτύου και τα αναλυτικά στοιχεία, η πολιτική βάσει δεδομένων και ο έλεγχος κλειστού βρόχου που βασίζεται σε AI. Εφαρμόζει διάφορες τεχνικές τεχνητής νοημοσύνης για τη δημιουργία πολιτικών συνειδητοποίησης περιβάλλοντος για δυναμική διαχείριση υπηρεσιών δικτύου σύμφωνα με τις μεταβαλλόμενες καταστάσεις δικτύου, τα επιχειρηματικά μοντέλα και τις απαιτήσεις των χρηστών. Αναμένεται να επιτρέψει στο σύστημα διαχείρισης και ελέγχου μαθαίνοντας από τις λειτουργίες του και τις οδηγίες του ανθρώπου και να πραγματοποιήσει αυτόματη διαδικασία παρακολούθησης και διαμόρφωσης δικτύου. Έτσι, μπορεί να μειώσει την ανθρώπινη προσπάθεια και τα λάθη, το λειτουργικό κόστος και το χρόνο στην αγορά νέων υπηρεσιών. Το ISG BAΔ έχει κυκλοφορήσει αρκετές προδιαγραφές για περιπτώσεις χρήσης, απαιτήσεις, διαχείριση πολιτικής με γνώμονα το πλαίσιο και το πλαίσιο απόδειξης της έννοιας (Zhao, 2020).

7.1.4 ISO / IEC

Η διεθνής επιτροπή προτύπων ISO/IEC JTC1/SC42 ιδρύθηκε τον Οκτώβριο του 2017. Ως κοινή επιτροπή μεταξύ ISO και IEC, το SC42 είναι υπεύθυνο για την τυποποίηση στον τομέα της AI. Διευκολύνει το ISO / IEC JTC1 στο πρόγραμμα τυποποίησης του AI και καθοδηγεί το ISO / IEC JTC1 στην ανάπτυξη εφαρμογών AI. Αν και το SC42 έχει αναπτύξει διάφορα πρότυπα για μεγάλα δεδομένα και τεχνητή νοημοσύνη, συμπεριλαμβανομένης της έννοιας και της ορολογίας, της αρχιτεκτονικής αναφοράς

και του πλαισίου του συστήματος AI, δεν έχει αναπτύξει πρότυπα για την εφαρμογή τεχνικών AI σε δίκτυα κινητής τηλεφωνίας (Letaief et al, 2019).

7.1.5 TM

Το Smart BPM είναι ένα έργο καταλύτης που ιδρύθηκε από το φόρουμ της TM και στοχεύει στη διερεύνηση των δυνατοτήτων εισαγωγής μοντέλου αποφάσεων βάσει τεχνητής νοημοσύνης στην επιχειρηματική διαδικασία του δικτύου τηλεπικοινωνιών, όπως διαχείριση πελατών, παροχή υπηρεσιών, διασφάλιση QoS και διαχείριση σφαλμάτων. Το AI επιτρέπει στα συστήματα ροής εργασίας να αντιδρούν αυτόματα σε εξαιρετικά συμβάντα κατά τη διάρκεια εννοχρηστώσεων κύκλου ζωής υπηρεσιών δικτύου, συμπεριλαμβανομένου του προγραμματισμού, της παράδοσης, της ανάπτυξης, της λειτουργίας. Το βαθύ νευρικό δίκτυο εφαρμόζεται στο σύστημα υποστήριξης που βασίζεται σε AI. Χρησιμοποιώντας δεδομένα εισόδου από τον εννοχρηστωτή, τη διαχείριση δικτύου και τις συσκευές δικτύου, έχει αποδειχθεί το μοντέλο απόδειξης για την ανίχνευση και την αποκατάσταση σφαλμάτων δικτύου (Kato et al, 2020).

7.1.6 CCSA

Η China Communications Standards Association (Ένωση Προτύπων Τηλεπικοινωνιών Κίνας - CCSA) ξεκίνησε αρκετές μελέτες για την εφαρμογή της τεχνητής νοημοσύνης στα δίκτυα τηλεπικοινωνιών από το 2017. Συγκεκριμένα, η CCSA TC1-WG1 ενέκρινε την πρόταση έργου μιας μελέτης σχετικά με την εφαρμογή της τεχνητής νοημοσύνης στην εξέλιξη του δικτύου τηλεπικοινωνιών (Tang et al, 2019).

7.2 Σημαντική έρευνα και πρακτικές της βιομηχανίας

7.2.1 SELFNET

Τον Ιούλιο του 2015, το έργο SELFNET στο πλαίσιο του προγράμματος EE H2020 ιδρύθηκε για να δημιουργήσει και να εφαρμόσει ένα έξυπνο πλαίσιο διαχείρισης δικτύου για δίκτυα 5G εντός 36 μηνών. Στόχος του ήταν να βοηθήσει τους χειριστές δικτύου 5G να απλοποιήσουν τα περίπλοκα καθήκοντα διαχείρισης και λειτουργίας του δικτύου, τα οποία μειώνουν τις λειτουργικές δαπάνες, συντομεύουν το χρόνο στην

αγορά νέων υπηρεσιών και βελτιώνουν την εμπειρία των χρηστών. Αξιοποιώντας αναδυόμενες τεχνολογίες όπως AI και δίκτυα ορισμένα από λογισμικό, το έργο στοχεύει να παρέχει τις δυνατότητες αυτοθεραπείας ενάντια σε αστοχίες δικτύου, αυτοβελτιστοποίηση για βελτίωση του QoE και αυτοπροστασία από καταναμημένες κυβερνοεπιθέσεις. Ένας από τους κύριους στόχους του SELFNET είναι η ευφυΐα δικτύου, η οποία επιτρέπει την αυτόνομη διαχείριση των δικτύων 5G, αντιμετωπίζοντας τα εντοπισμένα προβλήματα αντιδραστικά και προβλέποντας τα προβλήματα προληπτικά. Για το σκοπό αυτό, έχει σχεδιαστεί ένα σύστημα ελέγχου κλειστού βρόχου που ξεκινά από αισθητήρες και τερματίζει σε ενεργοποιητές. Παρόλο που το SELFNET παρέχει ένα πλαίσιο αυτόματης διαχείρισης υψηλού επιπέδου, οι κατάλληλοι αλγόριθμοι και τα μοντέλα μηχανικής μάθησης πρέπει να σχεδιαστούν προσεκτικά και να επαληθευτούν για την επίλυση πρακτικών προβλημάτων δικτύου (Sun et al, 2020).

7.2.2 CogNet

Για να αντιμετωπίσει την αυξανόμενη πολυπλοκότητα της διαχείρισης δικτύου 5G, τον Ιούλιο του 2015, ξεκίνησε το έργο EU H2020 CogNet για να επιτύχει το όραμα της αυτοματοποιημένης διαχείρισης δικτύου. Το έργο στοχεύει στη διασφάλιση της ποιότητας των υπηρεσιών, στη βελτίωση της λειτουργικής αποτελεσματικότητας και στη μείωση των λειτουργικών δαπανών αναπτύσσοντας ένα αυτόνομο πλαίσιο διαχείρισης δικτύου αυτοδιαχείρισης. Σε σύγκριση με την υπάρχουσα αρχιτεκτονική διαχείρισης δικτύου, το πλαίσιο που προτείνει το CogNet ενισχύεται τόσο από τεχνικές πραγματικού χρόνου όσο και από μηχανική μάθηση για να επιτρέψει ένα ελαστικό οικοσύστημα μεγάλων δεδομένων που μπορεί να χειριστεί με ευελιξία διάφορες περιπτώσεις χρήσης. Η κύρια καινοτομία του πλαισίου είναι η γνωστική έξυπνη μηχανή με δυνατότητα μηχανικής μάθησης, η οποία καθιστά δυνατή την δυναμική προσαρμογή πόρων στις μεταβαλλόμενες απαιτήσεις βάσει της μάθησης σε πραγματικό χρόνο (Hoyidis et al, 2020).

7.2.3 SLICENET

Το έργο EU H2020 SLICENET που ξεκίνησε τον Ιούνιο του 2017 επικεντρώνεται στη διαχείριση του γνωστικού δικτύου και στην ενορχήστρωση των slice από άκρο σε άκρο σε δίκτυα 5G που βασίζονται σε SDN/NFV σε πολλούς τομείς χειριστή. Το έργο

στοχεύει στην ανάπτυξη ενός νέου γνωστικού και ολοκληρωμένου πλαισίου διαχείρισης slice δικτύου 5G για κάθετες επιχειρήσεις, τη δημιουργία ευέλικτης διαχείρισης και διασφάλισης υπηρεσιών slice, την επίδειξη της αποτελεσματικότητας του πλαισίου στην παροχή υπηρεσιών 5G βασισμένων σε slice για κάθετους. Οι τρεις περιπτώσεις κάθετης χρήσης που εντοπίστηκαν από το SliceNet Project περιλαμβάνουν το eHealth, το Smart Grid, το Smart City (Nawaz et al, 2019).

7.2.4 5G-CLARITY

Για τη διευκόλυνση των καινοτόμων υπηρεσιών κρίσιμης επικοινωνίας για κάθετους χρήστες, το έργο EU H2020 5G-CLARITY στοχεύει στην ανάπτυξη αρχιτεκτονικής B5G για χρήστες κάθετης βιομηχανίας. Η αρχιτεκτονική χαρακτηρίζεται από ένα νέο δίκτυο πρόσβασης που ενσωματώνει WiFi, LiFi και 5G, καθώς και νέα στοιχεία διαχείρισης που επιτρέπουν στη AI να πραγματοποιεί αυτοματοποίηση δικτύου. Εκτός αυτού, θα καθορίσει νέες υπηρεσίες eMBB και URLLC με μετρήσιμες βελτιώσεις σε όρους χαμηλού λανθάνοντος χρόνου, αξιοπιστίας, χωρητικότητας περιοχής και ακριβούς εντοπισμού θέσης. Θα αναπτυχθεί ένα πλαίσιο διαχείρισης δικτύου SDN/NFV ενσωματωμένο με έναν κινητήρα AI για να επιτευχθεί αυτοματοποιημένη διαχείριση σύμφωνα με τις πολιτικές πρόθεσης από τους διαχειριστές. Με βάση τη διαχείριση που βασίζεται στο AI, το 5G-CLARITY θα επιτρέψει την αποτελεσματική παροχή, διαχείριση και βελτιστοποίηση slice δικτύου (Kaur et al, 2021).

7.2.5 ARIADNE

Το έργο EU H2020 ARIADNE στοχεύει στην πραγματοποίηση αποτελεσματικών ραδιοεπικοινωνιών υψηλού εύρους ζώνης, αναπτύσσοντας κρίσιμες νέες τεχνολογίες για 5G και πέρα από αυτό με ολοκληρωμένο τρόπο. Πρώτον, το έργο θα προτείνει νέες τεχνολογίες ραδιοεπικοινωνιών για ασύρματες επικοινωνίες βάσει ζωνών άνω των 100GHz. Εκτός αυτού, θα εκμεταλλευτεί ευκαιρίες για την προηγμένη συνδεσιμότητα που βασίζεται σε μετα-επιφάνειες, συντονίζοντας τα αντικείμενα ως ανακλαστήρες για τη διαμόρφωση του περιβάλλοντος του ραδιοφωνικού καναλιού στη ζώνη D. Επιπλέον, για να επιτευχθεί η δυναμική διαχείριση και αναδιαμόρφωση της μετα-επιφάνειας για την παροχή αξιόπιστων συνδέσεων υψηλού εύρους ζώνης, σχεδιάζει να αναπτύξει ένα έξυπνο σύστημα διαχείρισης χρησιμοποιώντας τεχνικές μηχανικής μάθησης και AI. Για να πραγματοποιήσει αυτές τις έννοιες, η ARIADNE προτείνει μια νέα

αρχιτεκτονική συστήματος βελτιστοποιημένη με ένα νέο πλαίσιο θεωρίας επικοινωνίας πέρα από το πρότυπο Shannon και αναπτύσσει προσεγγίσεις βασισμένες σε μηχανική μάθηση για προσαρμοστική διαχείριση πόρων ραδιοσυχνοτήτων, εξαιρετικά αξιόπιστη συνδεσιμότητα και βελτιστοποίηση δικτύου E2E (Zhang et al, 2019).

7.2.6 MonB5G

Πρόσφατα, το έργο EU H2020 MonB5G δημιουργήθηκε για να αντιμετωπίσει τις προκλήσεις της διαχείρισης και ενορχήστρωσης τεράστιων αριθμών slice δικτύου με διαφορετικές λειτουργίες, περιόδους και απαιτήσεις απόδοσης κατά την περίοδο B5G. Για να επιτευχθεί ο στόχος της μηδενικής αψής και της ενορχήστρωσης τεράστιων τμημάτων δικτύου, το έργο προτείνει ένα νέο πλαίσιο αυτόνομης διαχείρισης και ενορχήστρωσης, αξιοποιώντας κατανεμημένες τεχνολογίες AI που βασίζονται σε δεδομένα. Το ιεραρχικό, ανεκτικό στα σφάλματα και αυτοματοποιημένο πλαίσιο βάσει δεδομένων ενσωματώνουν την ασφάλεια και την ενεργειακή απόδοση ως βασικά χαρακτηριστικά. Το MonB5G θα επεκτείνει το υπάρχον πλαίσιο διαχείρισης και ενορχήστρωσης και κινητής υπολογιστικής αιχμής με ενσωματωμένες γνωστικές λειτουργίες και θα αναπτύξει μηχανισμούς εμπιστοσύνης για την εξασφάλιση λειτουργιών μεταξύ τομέων (du et al, 2020).

8 Προτάσεις για Μελλοντική Έρευνα

8.1 Σύνολο δεδομένων υψηλής ποιότητας από δίκτυα κινητής τηλεφωνίας

Το τεράστιο και υψηλής ποιότητας σύνολο δεδομένων είναι πολύ σημαντικό για τους αλγόριθμους βαθιάς μάθησης για την επίτευξη καλής απόδοσης. Καθώς τα μοντέλα βαθιάς μάθησης συνήθως περιέχουν πολλές παραμέτρους, ο μεγάλος όγκος και τα δεδομένα υψηλής ποιότητας είναι απαραίτητα για την εκπαίδευση μεγάλων και πολύπλοκων μοντέλων. Χωρίς επαρκή δεδομένα, η προσέγγιση απόδοσης βαθιάς μάθησης ενδέχεται να υποφέρει από αυτό το πρόβλημα. Σε αντίθεση με άλλους τομείς έρευνας, όπως η όραση του υπολογιστή και η επεξεργασία φυσικής γλώσσας, όπου υπάρχει επαρκές σύνολο δεδομένων υψηλής ποιότητας για τους ερευνητές για επαλήθευση και σύγκριση διαφορετικών αλγορίθμων, δεν υπάρχει διαθέσιμο δημόσιο σύνολο δεδομένων από δίκτυα κινητής τηλεφωνίας, επειδή οι φορείς εκμετάλλευσης κινητών δικτύων διατηρούν τα δεδομένα εμπιστευτικά λόγω ανησυχιών σχετικά με το απόρρητο των χρηστών. Εκτός αυτού, οι κανονισμοί προστασίας της ιδιωτικής ζωής των δεδομένων από τις κυβερνήσεις περιορίζουν την ανοιχτή πρόσβαση πραγματικών συνόλων δεδομένων από δίκτυα επικοινωνίας. Επομένως, η βιομηχανία δικτύου κινητής τηλεφωνίας πρέπει να δημιουργήσει σύνολα δεδομένων υψηλής ποιότητας από δίκτυα κινητής τηλεφωνίας μετά την κατάργηση ή απόκρυψη πληροφοριών απορρήτου των χρηστών. Επιπλέον, το σύνολο δεδομένων που συλλέγεται από αισθητήρες και κινητές συσκευές υπόκειται συνήθως σε απώλεια, ανισορροπία, πλεονασμό και εσφαλμένη σήμανση, τα οποία δεν μπορούν να χρησιμοποιηθούν για εκπαίδευση απευθείας. Επομένως, απαιτούνται περισσότερες ερευνητικές προσπάθειες για τη συλλογή δεδομένων κινητής τηλεφωνίας, τη συγκέντρωση, τον καθαρισμό, την ομαδοποίηση και την ανωνυμοποίηση. Ως πιθανές λύσεις για τον μετριασμό του συνόλου δεδομένων χωρίς πρόβλημα, οι τεχνολογίες μηχανικής μάθησης μπορούν να αξιοποιηθούν για να μετριάσουν τα προβλήματα. Το γενετικό δίκτυο αντιπαραθέσεων είναι μια πολλά υποσχόμενη προσέγγιση για τη δημιουργία συνθετικών δεδομένων για την υποβοήθηση των εποπτευόμενων μαθησιακών εργασιών. Αυτό είναι ιδιαίτερα σημαντικό για σενάρια δικτύου κινητής τηλεφωνίας όπου λείπει μεγάλο όγκο πραγματικών δεδομένων. Αξίζει να μελετηθεί η χρήση γενετικού δικτύου αντιπαραθέσεων για να εμπλουτιστεί το σύνολο δεδομένων εκπαίδευσης

δημιουργώντας συνθετικά δεδομένα από περιορισμένο πρακτικό σύνολο δεδομένων. Επιπλέον, όπως αποδεικνύεται από τις υπάρχουσες μελέτες, η μεταφορά μάθησης μπορεί να μειώσει σημαντικά την ποσότητα των απαιτούμενων δεδομένων για να επιτύχει την επιθυμητή απόδοση επαναχρησιμοποιώντας το μοντέλο που έχει μάθει σε άλλα παρόμοια σενάρια δικτύου.

8.2 Έξυπνη Ασφάλεια Δικτύου

Το ΑΙ προσφέρει τόσο ευκαιρίες όσο και προκλήσεις στην ασφάλεια δικτύου 6G και στην προστασία της ιδιωτικής ζωής των χρηστών. Από τη μία πλευρά, έχουν χρησιμοποιηθεί διάφοροι αλγόριθμοι μηχανικής μάθησης και βαθιάς μάθησης για την ενίσχυση της ασφάλειας του δικτύου, όπως ανίχνευση εισβολής, ανίχνευση μη φυσιολογικής κίνησης, ανίχνευση συμπεριφοράς κακόβουλου χρήστη. Αλλά οι περισσότερες από τις υπάρχουσες μελέτες επικεντρώνονται στην σταθερή πλευρά του δικτύου. Μόνο λίγα έργα που προσπάθησαν να βελτιώσουν την ασφάλεια του ασύρματου δικτύου αξιοποιώντας τις τεχνικές μηχανικής μάθησης είναι καλά παραδείγματα για την εξασφάλιση μελλοντικών ασύρματων δικτύων από την βαθιά μάθηση. Δεδομένης της ανοιχτής φύσης του ασύρματου καναλιού, της περιορισμένης χωρητικότητας του καναλιού και της ικανότητας επεξεργασίας των κόμβων του δικτύου, το ασύρματο δίκτυο είναι ιδιαίτερα ευάλωτο σε κακόβουλες επιθέσεις. Απαιτούνται περισσότερες ερευνητικές προσπάθειες για την ενίσχυση της προστασίας της ραδιοασφάλειας. Από την άλλη πλευρά, τα υπάρχοντα πλαίσια μηχανικής μάθησης και οι ίδιοι οι αλγόριθμοι αντιμετωπίζουν διάφορους κινδύνους ασφαλείας. Σε περίπτωση που η ασφάλεια δεν λαμβάνεται υπόψη στην αρχή της ανάπτυξης μηχανισμών που βασίζονται σε ΑΙ, οι επιτιθέμενοι μπορούν να χειραγωγήσουν το σύμπέρασμα που οδηγεί σε λανθασμένες αποφάσεις. Σε έξυπνα περιβάλλοντα 6G όπως αυτόνομα οχήματα, έξυπνες κατασκευές, οι επιθέσεις σε συστήματα ελέγχου που βασίζονται σε ΑΙ μπορεί να οδηγήσουν σε καταστροφικά αποτελέσματα. Επιπλέον, ενδέχεται να προκύψουν κίνδυνοι ασφαλείας κατά τη λειτουργία. Κακόβουλη έγχυση δεδομένων θα μπορούσε να παραπλανήσει τους πράκτορες ΑΙ να λάβουν λανθασμένες αποφάσεις. Για παράδειγμα, ένας κακόβουλος χρήστης μπορεί να μεταδώσει ψεύτικα σήματα για να παραπλανήσει τη διαδικασία εκπαίδευσης ΑΙ έτσι ώστε να μπορεί να έχει πρόσβαση σε περισσότερους πόρους του κοινόχρηστου φυσικού καναλιού, ενώ άλλοι χρήστες δεν δέχονται. Εκτός αυτού, η δηλητηρίαση δεδομένων αποτελεί μια

άλλη πρόκληση για τα συστήματα εντοπισμού εισβολών με βάση τη μη εποπτευόμενη μάθηση, καθώς μπορεί να αλλάξει τα δεδομένα που χρησιμοποιούνται για τον εντοπισμό κακόβουλων επιθέσεων. Επιπλέον, δεδομένου ότι απαιτούνται μεγάλες ποσότητες πραγματικών συνόλων δεδομένων για την εκπαίδευση μοντέλων ΑΙ, ο τρόπος αποτελεσματικής ανίχνευσης του κακόβουλου συνόλου δεδομένων είναι μια άλλη πρόκληση. Επομένως, η ακεραιότητα και το απόρρητο του συνόλου δεδομένων για την εκπαίδευση των μοντέλων μηχανικής μάθησης, η ευρωστία και η εμπιστευτικότητα των μοντέλων μηχανικής μάθησης πρέπει να αντιμετωπιστούν καλά κατά την ανάπτυξη μηχανισμών δικτύου με δυνατότητα ΑΙ.

8.3 Ολιστική Βελτιστοποίηση Δικτύου

Συμβατικά, προσεγγίσεις όπως δυναμικός προγραμματισμός, θεωρία παιχνιδιών και περιορισμένη βελτιστοποίηση χρησιμοποιούνται για την επίλυση διαφόρων προβλημάτων βελτιστοποίησης δικτύου. Ωστόσο, το διατυπωμένο μαθηματικό μοντέλο βασίζεται συνήθως στην ισχυρή υπόθεση σχετικά με την κυρτότητα αντικειμενικών συναρτήσεων ή το ιδανικό μοντέλο διανομής δεδομένων. Καθώς τα δίκτυα που εξελίσσονται προς το 6G γίνονται όλο και πιο περίπλοκα και δυναμικά, ορισμένες παραδοχές δεν θα είναι ρεαλιστικές. Είναι πιο δύσκολο να επιτευχθεί το βέλτιστο αποτέλεσμα των διατυπωμένων προβλημάτων με συμβατικές προσεγγίσεις λόγω μεγάλου αριθμού παραμέτρων και περιορισμών. Ευτυχώς, η υπολογιστική πολυπλοκότητα των αλγορίθμων βαθιάς μάθησης είναι ελεγχόμενη και ανεξάρτητη από την κλίμακα των παραμέτρων του δικτύου. Παρόλο που πολλά έργα έχουν προσπαθήσει να εφαρμόσουν τεχνικές μηχανικής μάθησης/βαθιάς μάθησης για την επίλυση διαφόρων προβλημάτων βελτιστοποίησης δικτύου και δείχνουν ενθαρρυντικά αποτελέσματα, τα περισσότερα από αυτά επικεντρώθηκαν σε ένα συγκεκριμένο σενάριο δικτύου όπως UAV, D2D και Satcom, σχεδόν καμία εργασία δεν επικεντρώνεται σε ολοκληρωμένα σενάρια δικτύου 6G διαστήματος-αέρα-γησ-ωκεανού μεγάλης κλίμακας. Οι προσεγγίσεις βαθιάς μάθησης ενίσχυσης δεν απαιτούν άκαμπτα μαθηματικά μοντέλα με βάση ισχυρές παραδοχές. Επιπλέον, μπορεί να αντιμετωπίσει το πρόβλημα με μεγάλους χώρους κατάστασης-δράσης με προσέγγιση λειτουργιών, γεγονός που καθιστά δυνατή την επίλυση προβλημάτων βελτιστοποίησης μεγάλης κλίμακας που είναι δύσκολο να επιλυθούν με συμβατικές προσεγγίσεις βελτιστοποίησης. Η πρόσφατη εργασία σχετικά με τη βελτιστοποίηση ολοκληρωμένων

δικτύων διαστήματος-αέρα-εδάφους από την βαθιά μάθηση έδειξε πολλά υποσχόμενα αποτελέσματα. Απαιτείται περαιτέρω μελέτη για την υλοποίηση ενός αυτοματοποιημένου συστήματος βελτιστοποίησης 6G κλειστού βρόχου, αξιοποιώντας τη βαθιά μάθηση ενίσχυσης. Ένας βρόχος ανατροφοδότησης μεταξύ του ελεγκτή πολιτικής βελτιστοποίησης και των οντοτήτων επιβολής της πολιτικής ή/και των οντοτήτων ανίχνευσης επιτρέπει στον ελεγκτή πολιτικής να επαναπροσδιορίζει επαναληπτικά την πολιτική/δράση βελτιστοποίησης συστήματος και να επιτυγχάνει τελικά τη βέλτιστη απόδοση. Η αξιοσημείωτη επιτυχία των Atari και Alfa Go δείχνει πως η βαθιά μάθηση ενίσχυσης θα είναι βασικός παράγοντας για την επίτευξη της βέλτιστης απόδοσης 6G σε δυναμικά και αβέβαια περιβάλλοντα.

8.4 Κατανεμημένη Πληροφόρηση σε Πραγματικό Χρόνο

Οι περισσότερες από τις υπάρχουσες λύσεις τεχνητής νοημοσύνης καταναλώνουν πολύ ενέργεια, πόρους και χρόνο, το οποίο μπορεί να μην είναι πρακτικό για τη γρήγορη αλλαγή ετερογενών καταστάσεων δικτύου 6G και των απαιτήσεων των χρηστών. Επομένως, το κινητό πρότυπο AI που περιλαμβάνει τόσο τη συγκεντρωτική νοημοσύνη cloud όσο και την κατανεμημένη ευφυΐα ακμής είναι κρίσιμο. Η κατανεμημένη και ελαφριά νοημοσύνη που είναι ενσωματωμένη στην άκρη του ασύρματου δικτύου μπορεί να συμβάλει σημαντικά στις υπηρεσίες εξαιρετικά χαμηλού λανθάνοντος χρόνου. Αναλύοντας τα δεδομένα και λαμβάνοντας αποφάσεις κοντά στον τόπο όπου δημιουργούνται τα δεδομένα, η ευφυΐα αιχμής μπορεί να μειώσει το κόστος μετάδοσης, τους κινδύνους ασφαλείας και την καθυστέρηση κατά τη μετάδοση δεδομένων. Ωστόσο, οι κατανεμημένοι κόμβοι αιχμής μπορεί να έχουν διαφορετικές δυνατότητες μάθησης και το τοπικό σύνολο δεδομένων μπορεί να είναι διαφορετικό σε μέγεθος και ποιότητα. Αυτό θα μπορούσε ενδεχομένως να οδηγήσει σε αστάθεια στον έλεγχο του δικτύου. Η εξασφάλιση της αξιοπιστίας της ευφυΐας αιχμής που βασίζεται σε τοπικά μικρά δεδομένα είναι ένα απαιτητικό ζήτημα. Η κοινή χρήση μερικών δεδομένων και εκπαιδευμένων μοντέλων AI μεταξύ κατανεμημένων παραγόντων AI αντί για ανεπεξέργαστα δεδομένα θα μειώσει σημαντικά την επιβάρυνση και τον λανθάνοντα χρόνο της επικοινωνίας. Εκτός αυτού, η κατάρτιση μοντέλων υψηλής ποιότητας με την πάροδο του χρόνου, αξιοποιώντας τη σταδιακή μάθηση και υιοθετώντας εκπαιδευμένα μοντέλα μέσω απόσταξης γνώσης και μάθησης μεταφοράς, είναι χρήσιμη για την αντιμετώπιση της μικρής διαθεσιμότητας δεδομένων στην αιχμή.

Επιπλέον, για να βελτιωθεί η αποτελεσματικότητα των υπαρχουσών τεχνικών βαθιάς μάθησης, η βαθιά μάθηση με τη βοήθεια ειδικών γνώσεων είναι κρίσιμη. Στο πλαίσιο του συστήματος 6G, η αξιοποίηση μεθόδων βαθιάς μάθησης βάσει δεδομένων με γνώσεις εμπειρογνομώνων βασισμένων σε θεωρητικά μοντέλα έχει μεγάλες δυνατότητες. Αν και τα μαθηματικά μοντέλα που έχουν δημιουργηθεί για το σύστημα 6G μπορεί να είναι ανακριβή ή δυσδιάκριτα, είναι χρήσιμα για προσεγγίσεις βάσει δεδομένων για βελτιστοποίηση ή βελτίωση των μοντέλων πιο γρήγορα. Αποκαλύφθηκε ότι οι κοινές προσεγγίσεις που βασίζονται σε δεδομένα και σε μοντέλα μπορούν να μειώσουν σημαντικά την πολυπλοκότητα των μεθόδων που βασίζονται αποκλειστικά σε μοντέλα και επιτρέπουν την απόκριση δικτύου σε πραγματικό χρόνο. Εν τω μεταξύ, μπορούν να επιτύχουν σχεδόν βέλτιστη απόδοση με πολύ λιγότερη ποσότητα δεδομένων σε σύγκριση με μεθόδους που βασίζονται αποκλειστικά σε δεδομένα. Αξίζει να επιτευχθεί περισσότερη προσπάθεια για την επίτευξη ενός ρεαλιστικού παραδείγματος 6G AI συνδυάζοντας προσεγγίσεις βαθιάς μάθησης που βασίζονται σε δεδομένα και συμβατικές μεθόδους βασισμένες σε μαθηματικά μοντέλα με μάθηση μεταφοράς.

8.5 Επαλήθευση μέσω πρακτικής εφαρμογής

Τα περισσότερα από τα υπάρχοντα έργα για την εφαρμογή μηχανικής μάθησης/βαθιάς μάθησης σε προβλήματα δικτύου κινητής τηλεφωνίας αποδεικνύουν την απόδοση των μεθόδων τους μέσω προσομοιώσεων. Μόνο λίγα έργα προσπάθησαν να επαληθεύσουν την απόδοση μέσω πρακτικής εφαρμογής. Συνήθως, συνθετικά σύνολα δεδομένων δικτύου αντί για πραγματικά δεδομένα δικτύου χρησιμοποιούνται στην εκπαίδευση και την επικύρωση. Τα κριτήρια αξιολόγησης που χρησιμοποιούνται στη βιβλιογραφία για την επικύρωση λύσεων που βασίζονται σε μηχανική μάθηση συχνά δεν είναι ρεαλιστικά λόγω της μεγάλης διαφοράς μεταξύ των ρυθμίσεων προσομοίωσης και των πραγματικών περιβαλλόντων δικτύου. Για παράδειγμα, το διαφορετικό και δυναμικό φυσικό κανάλι σε πρακτικά σενάρια είναι πολύ πιο περίπλοκο από το περιβάλλον καναλιού στο σύστημα προσομοίωσης που δημιουργείται από μαθηματικά μοντέλα. Το πραγματικό σύνολο δεδομένων από πραγματικά δίκτυα είναι πολύ πιο διαφορετικό από την κίνηση δεδομένων που δημιουργείται από λογισμικό προσομοίωσης. Αν και οι περισσότερες από τις λύσεις που προτείνονται στη βιβλιογραφία αποδίδουν καλά σε τέτοιες καταστάσεις, η δυνατότητα εφαρμογής σε πρακτικό περιβάλλον δικτύου

παραμένει αμφισβητήσιμη. Επομένως, υπάρχει ακόμη πολύς δρόμος για να εισαχθούν αυτές οι προσεγγίσεις που βασίζονται σε μηχανική μάθηση στο σύστημα 6G. Απαιτείται περισσότερη προσπάθεια για να υπάρξει η μεταβολή από τη μελέτη που βασίζεται στην προσομοίωση στην πρακτική μελέτη που βασίζεται στην εφαρμογή. Για να είναι δυνατή, είναι απαραίτητες ανοιχτές πηγές και προγραμματιζόμενες πλατφόρμες υλικού, όπως πίνακας πύλης με δυνατότητα προγραμματισμού πεδίου, προγραμματιζόμενα τσιπ, αναδιαμορφώσιμο υλικό για ραδιοεπικοινωνίες. Επιπλέον, το αυθεντικό σύνολο δεδομένων από πρακτικά δίκτυα κινητής επικοινωνίας είναι σημαντικό για τους ερευνητές, ώστε να μπορούν να επαληθεύσουν την απόδοση νέων ιδεών και να συγκρίνουν διαφορετικές μεθόδους.

9 Συμπεράσματα

Το σύστημα 6G προβλέπεται να υποστηρίζει διάφορες νέες εφαρμογές με αναδυόμενες ασύρματες τεχνολογίες και νέα παραδείγματα. Ωστόσο, πολλά τεχνικά ζητήματα πρέπει να αντιμετωπιστούν για την επίτευξη του φιλόδοξου στόχου του συστήματος 6G. Το AI αναμένεται να διαδραματίσει σημαντικό ρόλο στα δίκτυα 6G. Αυτή η εργασία παρουσιάζει το όραμα του 6G με δυνατότητα AI και διερευνά διεξοδικά μεγάλα ζητήματα δικτύου που μπορούν να επιλυθούν με μηχανική μάθηση/βαθιά μάθηση, όπως Advanced Wireless Interface, έξυπνο έλεγχο κυκλοφορίας, διαχείριση και ενορχήστρωση, βελτιστοποίηση δικτύου και ασφάλεια δικτύου. Εξετάζεται η τελευταία πρόοδος των βιομηχανικών προγραμμάτων τυποποίησης και έρευνας σχετικά με την εισαγωγή AI στο δίκτυο προς το 6G. Αναθεωρώντας τις τελευταίες μελέτες, εντοπίζονται πιθανές μελλοντικές ερευνητικές ευκαιρίες όπως σύνολο δεδομένων υψηλής ποιότητας, έξυπνη ασφάλεια δικτύου, ολιστική βελτιστοποίηση δικτύου, ευφυΐα σε πραγματικό χρόνο, επαλήθευση μέσω πρακτικής εφαρμογής. Γενικά, αν και πολλά ακαδημαϊκά έργα έχουν αποκαλύψει τα πιθανά οφέλη της εφαρμογής μηχανικής μάθησης/βαθιάς μάθησης σε δίκτυα κινητής τηλεφωνίας, η πρακτική εφαρμογή της τεχνητής νοημοσύνης σε εμπορικά δίκτυα είναι ακόμη αρκετά περιορισμένη. Συνεπώς, απαιτούνται περισσότερες προσπάθειες για να γίνει ευρεία χρήση της τεχνητής νοημοσύνης σε πρακτικά δίκτυα. Εκτός αυτού, τα δίκτυα 6G βρίσκονται ακόμη στα πρώιμα στάδιά τους και οι αναδυόμενες τεχνολογίες δεν είναι ώριμες. Υπάρχει μια καλή ευκαιρία να υιοθετηθεί η μηχανική μάθηση σε σχεδιασμό αρχιτεκτονικής 6G από την αρχή για να επιτευθεί ένα εγγενές AI 6G.

Βιβλιογραφία

- Ali, S., Saad, W., Rajatheva, N., Chang, K., Steinbach, D., Sliwa, B., Wietfeld, C., Mei, K., Shiri, H., Zepernick, H.J. and Chu, T.M.C., 2020. 6G white paper on machine learning in wireless communication networks. *arXiv preprint arXiv:2004.13875*.
- Bhat, J.R. and Alqahtani, S.A., 2021. 6G Ecosystem: Current Status and Future Perspective. *IEEE Access*, 9, pp.43134-43167.
- Catak, E., Catak, F.O. and Moldsvor, A., 2021. Adversarial Machine Learning Security Problems for 6G: mmWave Beam Prediction Use-Case. *arXiv preprint arXiv:2103.07268*.
- Catak, F.O., Catak, E., Kuzlu, M. and Cali, U., 2021. Security Concerns on Machine Learning Solutions for 6G Networks in mmWave Beam Prediction. *arXiv preprint arXiv:2105.03905*.
- Cousik, T., Shafin, R., Zhou, Z., Kleine, K., Reed, J. and Liu, L., 2019. CogRF: A new frontier for machine learning and artificial intelligence for 6G RF systems. *arXiv preprint arXiv:1909.06862*.
- Dang, S., Amin, O., Shihada, B. and Alouini, M.S., 2019. From a human-centric perspective: What might 6G be?.
- Dang, S., Amin, O., Shihada, B. and Alouini, M.S., 2020. What should 6G be?. *Nature Electronics*, 3(1), pp.20-29.
- David, K., Elmirghani, J., Haas, H. and You, X.H., 2019. Defining 6G: Challenges and opportunities [from the guest editors]. *IEEE Vehicular Technology Magazine*, 14(3), pp.14-16.
- Du, J., Jiang, C., Wang, J., Ren, Y. and Debbah, M., 2020. Machine Learning for 6G Wireless Networks: Carrying Forward Enhanced Bandwidth, Massive Access, and Ultrareliable/Low-Latency Service. *IEEE Vehicular Technology Magazine*, 15(4), pp.122-134.
- Fettweis, G.P., 2014. The tactile internet: Applications and challenges. *IEEE Vehicular Technology Magazine*, 9(1), pp.64-70.

- Guo, W., 2020. Explainable artificial intelligence for 6G: Improving trust between human and machine. *IEEE Communications Magazine*, 58(6), pp.39-45.
- Hodge, J.A., Mishra, K.V., Nguyen, Q.M. and Zaghloul, A., 2021. Reconfigurable-Metasurface-Aided Multi-State Generalized Polarization-Space Modulation for Next-Generation Wireless Communications. *arXiv preprint arXiv:2103.12573*.
- Hoydis, J., Aoudia, F.A., Valcarce, A. and Viswanathan, H., 2020. Towards a 6G AI-Native Air Interface. *arXiv preprint arXiv:2012.08285*.
- Jagannath, A., Jagannath, J. and Melodia, T., 2020. Redefining wireless communication for 6G: Signal processing meets deep learning. *arXiv preprint arXiv:2004.10715*.
- Jameel, F., Sharma, N., Khan, M.A., Khan, I., Alam, M.M., Mastorakis, G. and Mavromoustakis, C.X., 2020. Machine learning techniques for wireless-powered ambient backscatter communications: Enabling intelligent IoT networks in 6G era. In *Convergence of Artificial Intelligence and the Internet of Things* (pp. 187-211). Springer, Cham.
- Jiang, W., Han, B., Habibi, M.A. and Schotten, H.D., 2021. The road towards 6G: A comprehensive survey. *IEEE Open Journal of the Communications Society*, 2, pp.334-366.
- Kato, N., Mao, B., Tang, F., Kawamoto, Y. and Liu, J., 2020. Ten challenges in advancing machine learning technologies toward 6G. *IEEE Wireless Communications*, 27(3), pp.96-103.
- Kaur, J., Khan, M.A., Iftikhar, M., Imran, M. and Haq, Q.E.U., 2021. Machine learning techniques for 5g and beyond. *IEEE Access*, 9, pp.23472-23488.
- Kaur, J., Khan, M.A., Iftikhar, M., Imran, M. and Haq, Q.E.U., 2021. Machine learning techniques for 5g and beyond. *IEEE Access*, 9, pp.23472-23488.
- Khan, L.U., Yaqoob, I., Imran, M., Han, Z. and Hong, C.S., 2020. 6G wireless systems: A vision, architectural elements, and future directions. *IEEE Access*, 8, pp.147029-147044.
- Letaief, K.B., Chen, W., Shi, Y., Zhang, J. and Zhang, Y.J.A., 2019. The roadmap to 6G: AI empowered wireless networks. *IEEE Communications Magazine*, 57(8), pp.84-90.
- Liu, Y., Yi, W., Ding, Z., Liu, X., Dobre, O. and Al-Dhahir, N., 2021. Application of noma in 6g networks: Future vision and research opportunities for next generation multiple access. *arXiv preprint arXiv:2103.02334*.

- Liu, Y., Yuan, X., Xiong, Z., Kang, J., Wang, X. and Niyato, D., 2020. Federated learning for 6g communications: Challenges, methods, and future directions. *China Communications*, 17(9), pp.105-118.
- Lovén, L., Leppänen, T., Peltonen, E., Partala, J., Harjula, E., Porambage, P., Ylianttila, M. and Riekkki, J., 2019. EdgeAI: A vision for distributed, edgenative artificial intelligence in future 6G networks. *The 1st 6G Wireless Summit*, pp.1-2.
- Lu, Y. and Ning, X., 2020. A vision of 6G–5G's successor. *Journal of Management Analytics*, 7(3), pp.301-320.
- Nawaz, S.J., Sharma, S.K., Wyne, S., Patwary, M.N. and Asaduzzaman, M., 2019. Quantum machine learning for 6G communication networks: State-of-the-art and vision for the future. *IEEE Access*, 7, pp.46317-46350.
- Nayak, S. and Patgiri, R., 2021. 6G communication technology: A vision on intelligent healthcare. In *Health Informatics: A Computational Perspective in Healthcare* (pp. 1-18). Springer, Singapore.
- Priya, B. and Malhotra, J., 2021. QAAs: QoS provisioned artificial intelligence framework for AP selection in next-generation wireless networks. *Telecommunication Systems*, 76(2), pp.233-249.
- Rodrigues, T.K., Suto, K. and Kato, N., 2019. Edge cloud server deployment with transmission power control through machine learning for 6G internet of things. *IEEE Transactions on Emerging Topics in Computing*.
- Saad, W., Bennis, M. and Chen, M., 2019. A vision of 6G wireless systems: Applications, trends, technologies, and open research problems. *IEEE network*, 34(3), pp.134-142.
- Saad, W., Bennis, M. and Chen, M., 2019. A vision of 6G wireless systems: Applications, trends, technologies, and open research problems. *IEEE network*, 34(3), pp.134-142.
- Shaikh, R.A.J., Naidu, H. and Kokate, P.A., 2021. Next-generation wsn for environmental monitoring employing big data analytics, machine learning and artificial intelligence. In *Evolutionary computing and mobile sustainable networks* (pp. 181-196). Springer, Singapore.
- Shuja, J., Bilal, K., Alasmay, W., Sinky, H. and Alanazi, E., 2021. Applying machine learning techniques for caching in next-generation edge networks: A comprehensive survey. *Journal of Network and Computer Applications*, p.103005.

- Sun, Y., Liu, J., Wang, J., Cao, Y. and Kato, N., 2020. When machine learning meets privacy in 6g: A survey. *IEEE Communications Surveys & Tutorials*, 22(4), pp.2694-2724.
- Tang, F., Kawamoto, Y., Kato, N. and Liu, J., 2019. Future intelligent and secure vehicular network toward 6G: Machine-learning approaches. *Proceedings of the IEEE*, 108(2), pp.292-307.
- Tang, F., Mao, B., Kawamoto, Y. and Kato, N., 2021. Survey on Machine Learning for Intelligent End-to-End Communication towards 6G: From Network Access, Routing to Traffic Control and Streaming Adaption. *IEEE Communications Surveys & Tutorials*.
- Tomkos, I., Klouidis, D., Pikasis, E. and Theodoridis, S., 2020. Toward the 6G network era: Opportunities and challenges. *IT Professional*, 22(1), pp.34-38.
- Viswanathan, H. and Mogensen, P.E., 2020. Communications in the 6G era. *IEEE Access*, 8, pp.57063-57074.
- Wang, C.X., Haider, F., Gao, X., You, X.H., Yang, Y., Yuan, D., Aggoune, H.M., Haas, H., Fletcher, S. and Hepsaydir, E., 2014. Cellular architecture and key technologies for 5G wireless communication networks. *IEEE communications magazine*, 52(2), pp.122-130.
- Wilhelmi, F., Carrascosa, M., Cano, C., Jonsson, A., Ram, V. and Bellalta, B., 2021. Usage of network simulators in machine-learning-assisted 5g/6g networks. *IEEE Wireless Communications*, 28(1), pp.160-166.
- Xiao, Y., Shi, G., Li, Y., Saad, W. and Poor, H.V., 2020. Toward Self-Learning Edge Intelligence in 6G. *IEEE Communications Magazine*, 58(12), pp.34-40.
- Yang, H., Alphones, A., Xiong, Z., Niyato, D., Zhao, J. and Wu, K., 2020. Artificial-Intelligence-Enabled Intelligent 6G Networks. *IEEE Network*, 34(6), pp.272-280.
- You, X., Wang, C.X., Huang, J., Gao, X., Zhang, Z., Wang, M., Huang, Y., Zhang, C., Jiang, Y., Wang, J. and Zhu, M., 2021. Towards 6G wireless communication networks: Vision, enabling technologies, and new paradigm shifts. *Science China Information Sciences*, 64(1), pp.1-74.
- Zhang, S., Liu, J., Guo, H., Qi, M. and Kato, N., 2020. Envisioning device-to-device communications in 6G. *IEEE Network*, 34(3), pp.86-91.

- Zhang, Z., Xiao, Y., Ma, Z., Xiao, M., Ding, Z., Lei, X., Karagiannidis, G.K. and Fan, P., 2019. 6G wireless networks: Vision, requirements, architecture, and key technologies. *IEEE Vehicular Technology Magazine*, 14(3), pp.28-41.
- Zhao, Y., 2020. A survey of 6G wireless communications: Emerging technologies. *arXiv preprint arXiv:2004.08549*.
- Zong, B., Fan, C., Wang, X., Duan, X., Wang, B. and Wang, J., 2019. 6G technologies: Key drivers, core requirements, system architectures, and enabling technologies. *IEEE Vehicular Technology Magazine*, 14(3), pp.18-27.