

Primjena umjetne inteligencije u mrežama nove generacije

Obrovac, Marijo

Undergraduate thesis / Završni rad

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Dubrovnik / Sveučilište u Dubrovniku**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/um:nbn:hr:155:350025>

Rights / Prava: [In copyright/Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-05-17**



Repository / Repozitorij:

[Repository of the University of Dubrovnik](#)

SVEUČILIŠTE U DUBROVNIKU
ODJEL ZA ELEKTROTEHNIKU I RAČUNARSTVO

Marijo Obrovac

PRIMJENA UMJETNE INTELIGENCIJE U MREŽAMA
NOVE GENERACIJE

ZAVRŠNI RAD

Dubrovnik, rujan 2022.

SVEUČILIŠTE U DUBROVNIKU
ODJEL ZA ELEKTROTEHNIKU I RAČUNARSTVO

PRIMJENA UMJETNE INTELIGENCIJE U MREŽAMA
NOVE GENERACIJE

ZAVRŠNI RAD

Studij: Primijenjeno/poslovno računarstvo

Kolegij: Arhitektura mreža nove generacije

Mentor: izv. prof. dr. sc. Adriana Lipovac

Student: Marijo Obrovac

Dubrovnik, rujan 2022.

SAŽETAK

Radijske mreže sljedeće generacije (tj. 5G i dalje), koje će biti iznimno dinamične i složene zbog ultra gусте implementacije heterogenih mreža, predstavljaju mnoge kritične izazove za planiranje mreže, rad, upravljanje i rješavanje problema. Istodobno, generiranje i potrošnja radijskih podataka postaju sve više distribuirani uz stalnu promjenu paradigme od komunikacija usmjerenih na ljude, prema strojno orijentiranim komunikacijama, čineći rad budućih radijskih mreža još složenijim. U ublažavanju složenosti budućeg mrežnog rada, novi pristupi inteligentnog korištenja distribuiranih računalnih resursa s poboljšanom svjesnošću konteksta postaju iznimno važni. Zbog toga, novonastala arhitektura, kojoj je cilj distribuciju računalstva, pohrane, kontrole komunikacija i mrežnih funkcija približiti što bliže krajnjim korisnicima, ima veliki potencijal za omogućavanje učinkovitog rada budućih radijskih mreža. Ove obećavajuće vrste arhitektura čine usvajanje principa umjetne inteligencije (engl. *Artificial Intelligence*), koji uključuju učenje, rasuđivanje i mehanizme donošenja odluka, prirodnim izborom za projektiranje čvrsto integrirane mreže. U tu svrhu, ovaj rad pruža opsežnu analizu korištenja AI koji integrira tehnike strojnog učenja, analize podataka i obrade prirodnog jezika (engl. *Natural language processing*) za poboljšanje učinkovitosti rada radijske mreže. Opisano sam korištenje ovih tehnika za učinkovito prikupljanje podataka, otkrivanje znanja, planiranje mreže, rad i upravljanje radijskim mrežama sljedeće generacije. Priložena je i kratka studija slučaja koja koristi AI tehnike za ovu mrežu.

Ključne riječi: Umjetna (strojna) inteligencija, radijska veza svjesna konteksta, strojno učenje, ontologija

ABSTRACT

Abstract – Next-generation wireless networks (i.e., 5G and beyond), which will be extremely dynamic and complex due to the ultra-dense deployment of heterogeneous networks, pose many critical challenges for network planning, operation, management, and troubleshooting. At the same time, the generation and consumption of wireless data are becoming increasingly distributed with an ongoing paradigm shift from people-centric to machine-oriented communications, making the operation of future wireless networks even more complex. In mitigating the complexity of future network operations, new approaches to intelligently utilizing distributed computational resources with improved context awareness become extremely important. In this regard, the emerging fog (edge) computing architecture aiming to distribute computing, storage, control, communication, and networking functions closer to end users, has great potential for enabling the efficient operation of future wireless networks. These promising architectures make the adoption of artificial intelligence (AI) principles, which incorporate learning, reasoning, and decision-making mechanisms, natural choices for designing a tightly integrated network. To this end, this article provides a comprehensive survey on the utilization of AI integrating machine learning, data analytics, and natural language processing (NLP) techniques for enhancing the efficiency of wireless network operation. The utilization of these techniques is described for efficient data acquisition, knowledge discovery, network planning, operation, and management of next-generation wireless networks. A brief case study utilizing the AI techniques for this network has also been provided.

Keywords: Artificial (machine) intelligence, context-aware wireless, machine learning, ontology

SADRŽAJ

SAŽETAK	3
ABSTRACT	4
1. UVOD	1
1.1. Definicija rada	1
1.2. Svrha i ciljevi rada	2
1.3. Metodologija rada	2
1.4. Struktura rada	3
2. PRIKUPLJANJE PODATAKA I OTKRIĆE ZNANJA	4
2.1. Prikupljanje podataka	4
2.2. Otkrivanje znanja	6
3. USLUGE U 5G MREŽI	7
4. RAD I UPRAVLJANJE MREŽOM	9
4.1. Raspodjela i upravljanje resursima	9
4.2. Sigurnost i zaštita privatnosti	10
4.3. Optimizacija kašnjenja za taktilne aplikacije	10
5. STUDIJE SLUČAJA DIZAJNA	13
5.1. Subjektivna metoda	13
5.2. Objektivna metoda	14
6. POZADINA STROJNOG UČENJA	15
7. ČOVJEK PROTIV STROJA	19
8. POJAM UMJETNE INTELIGENCIJE	20
9. RAZVOJ UMJETNE INTELIGENCIJE U 5G MREŽAMA	22
10. ZAKLJUČAK	23
LITERATURA	24
PRILOZI	28

Popis slika 28

Popis tablica 28

1. UVOD

Pojava pete generacije (5G) radijskih veza mreže i njena konvergencija s vertikalnim aplikacijama predstavljaju temelj budućeg povezanog društva za koju se očekuje da će podržati 125 milijardi uređaja 2030. godine (*IHS Markit*). Kako ove aplikacije i uređaji karakteriziraju sveprisutni zahtjevi za povezivanjem, buduće 5G mreže i dalje postaju sve više kompleksne. Osim složenosti povećanja baze stanice i korisničke opreme, značajni izazovi nastaju od početnog planiranja mreže do raspoređivanja i djelovanja ovisno o situaciji i fazi upravljanja. Mrežna arhitektura 5G i šire je heterogena i višeslojna s ultra gusto raspoređenim malim stanicama za postizanje tisuću puta većeg kapaciteta. Na primjer, mješovita upotreba planiranih i centralno kontroliranih makro baznih stanica i nasumično implementirane radijske pristupne točke (*WiFi*) u ultra gustoj heterogenoj mreži dovodi do nekoliko neočekivanih scenarija rada, koje nije moguće predvidjeti u fazi projektiranja mrežne. To zahtijeva da buduće radijske mreže imaju sposobnosti samoorganiziranja, konfiguriranja i samoispravka na temelju operativnog stanja, kroz usku koordinaciju između različitih čvorova, razina i komunikacijskih slojeva. Ovi izazovi naglašavaju da postojeće strategije mrežnog dizajna, koje koriste relativno jednostavnu statistiku, donose neprihvatljive performanse (na primjer, u smislu spektra i energetske učinkovitosti, pokrivenosti, kašnjenja i troška).

1.1. Definicija rada

Predmet istraživanja završnog rada je istražiti i analizirati primjenu umjetne inteligencije u mrežama nove generacije. Tu prvenstveno mislim na radijske mreže sljedeće generacije 5G, pa nadalje. Radijske mreže sljedeće generacije će biti iznimno dinamične i složene zbog ultra guste implementacije heterogenih mreža, i one predstavljaju mnoge kritične izazove za planiranje mreže, rad, upravljanje Predmet i rješavanje problema. Istodobno, generiranje i potrošnja radijskih podataka postaju sve više distribuirani uz stalnu promjenu paradigme od komunikacija usmjerenih na ljude prema strojno orijentiranim komunikacijama, čineći rad budućih radijskih mreža još složenijim. Proučavanjem navedene teme može se vidjeti kako će u budućnosti mrežna arhitektura 5G i šire biti neizbjježno heterogena i višeslojna s ultra gusto raspoređenim malim stanicama za postizanjem tisuću puta većeg kapaciteta.

1.2. Svrha i ciljevi rada

Svrha rada je prikazati kako se može poboljšati primjena umjetne inteligencije u mrežama nove generacije. Glavni cilj rada je opisati tehnologiju umjetne inteligencije koja je danas prisutna, te navesti neke dobre primjere u kojima se ona koristi. Razlog za odabir teme je činjenica kako su zadnjih godina u sve većem porastu razvoj strojnog učenja i primjena intelligentnih sustava, a o tome se zna vrlo malo. Danas možemo sa sigurnošću reći da će umjetna inteligencija obilježiti sljedeća stoljeća, te da će pokrenuti novu tehnološku revoluciju i da će promijeniti naše živote na način koji u ovom trenutku ne možemo sagledati.

1.3. Metodologija rada

Poboljšanje mehanizma zaključivanja ES-a postići će se kombinirajući najpoznatije metode umjetne inteligencije AI (engl. *Artificial Intelligence*) teorija neizrazitih logičkih skupova, te neuronskih mreža. Kombinacija ovih dviju metoda u literaturi je poznatija kao *Neuro Fuzzy* metoda i ta se metoda danas vrlo često koristi u područjima istraživanja. U stručnoj literaturi iz područja materijala nije pronađen problem čije se rješenje temelji na umjetnoj inteligenciji, a koja istovremeno koristi metodologiju ekspertnih sustava, neuronskih mreža itd. Predviđena je izgradnja ekspertnog sustava s takvim mehanizmom zaključivanja koji će sadržavati sljedeće mehanizme za objašnjavanje i zaključivanje: 1. Kako?: objašnjava neko predloženo rješenje, redoslijed pravila te slijed zaključivanja s faktorima sigurnosti; 2. Što ako?: omogućava promjene bilo koje varijable, te ponovno razmatranje predloženog rješenja od strane ES-a; 3 Zašto?: objašnjava trenutno postavljeno pitanje te pojmove unutar istog; 4. Rješenje?: daje rješenje u bilo kojem trenutku konverzacije. U mehanizam zaključivanja ugraditi će se procedure koje će automatski predlagati rješenje nakon prikupljanja određenog broja činjenica.

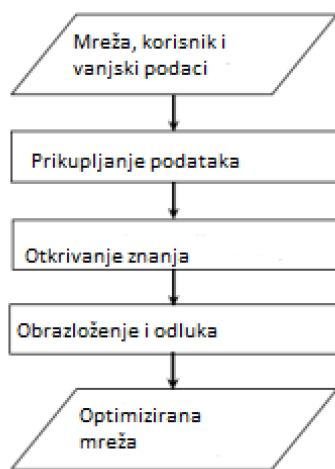
1.4. Struktura rada

Rad se sastoji od 10 poglavlja koji međusobno čine jednu zaokruženu cjelinu. U prvom poglavlju se uvodi čitatelja u strukturu rada. Navode se metodologija rada, definicija, svrha i cilj rada što će čitatelju svakako dati jasnu predodžbu o čemu će se pisati. Drugo poglavlje se odnosi na prikupljanje podataka i otkrivanje znanja o radijskim mrežama, jer je to jedan od zahtjeva budućih radijskih mreža koji pomaže u realizaciji svjesnih situacija i optimiziranih odluka. Treće poglavlje se odnosi na usluge u mreži kao na primjer pametna vozila, transport, infrastruktura i slično. Četvrti dio obraduje rad i upravljanje mrežom. U tom dijelu opisani su redom raspodjela resursa i njihovo upravljanje, sigurnost i zaštita privatnosti i optimizacija kašnjenja za taktilne aplikacije. U petom dijelu prikazane su dvije metode studije slučaja dizajna a to su subjektivna i objektivna metoda. Šesti dio prikazuje pozadinu strojnog učenja. U sedmom dijelu prikazana je tema čovjek protiv stroja. U osmom dijelu prikazano je općenito o umjetnoj inteligenciji kada se razvila i kako. U devetom dijelu prikazan je razvoj umjetne inteligencije u 5G mrežama. Deseti dio je zaključak završnog rada.

2. PRIKUPLJANJE PODATAKA I OTKRIĆE ZNANJA

Učinkovito prikupljanje podataka i otkrivanje znanja jedan je od zahtjeva budućih radijskih mreža, jer pomaže u realizaciji svjesnih situacija i optimiziranih odluka, kao što je prikazano na slici 1. Prikupljeni podaci se moraju učinkovito obraditi kako bi se izvuklo relevantno znanje. Nadalje, budući da dostupni podaci mogu sadržavati veliku količinu pogrešnih (nedostajućih) vrijednosti, možda će biti potrebno osmisliti robusno otkriće znanja [1].

Na slici broj 1. prikazan je optimizirani dizajn mreže s AI tehnikama



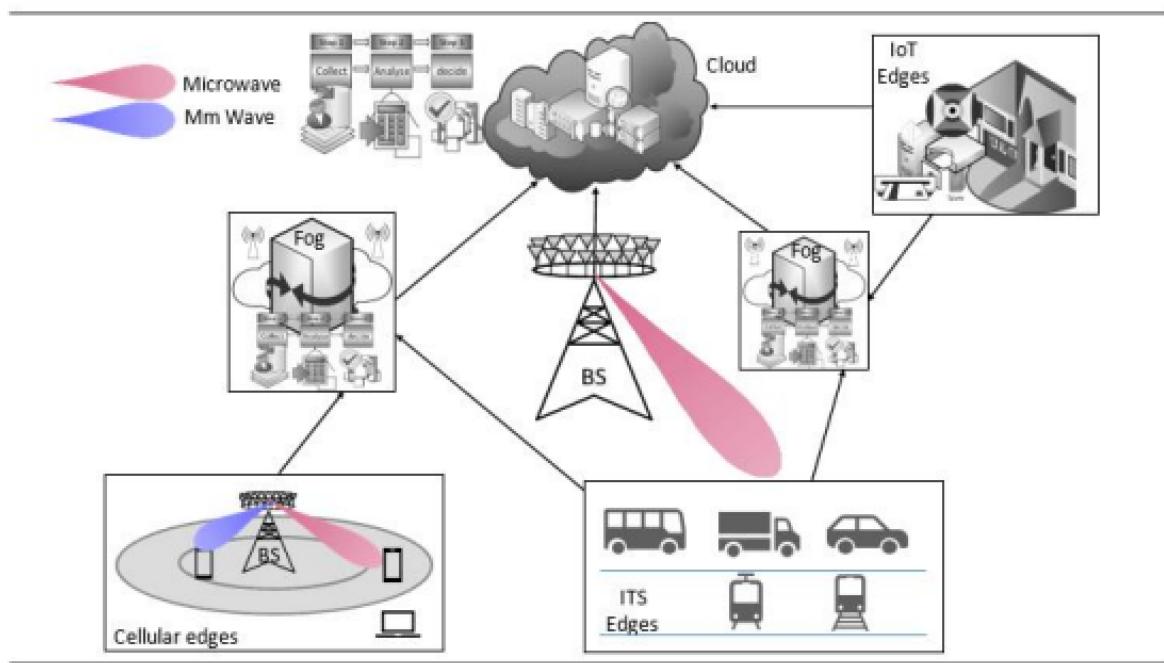
Slika 1: Optimizirani dizajn mreže s AI tehnikama

2.1. Prikupljanje podataka

Alati temeljeni na umjetnoj inteligenciji koji se oslanjaju na strojno učenje za unos podataka za rudarenje i ekstrakciju modela znanja na različitim razinama mogu biti primjenjeni na različitim razinama [3]. To uključuje staničnu razinu, razinu klastera stanica i razinu korisnika. Općenito, mogu se prikupljati podaci iz tri glavna izvora; mreže, korisnika i vanjskih uređaja. Mrežni podaci karakteriziraju ponašanje mreže uključujući ispad i statistiku korištenja usluga ili čvorova, te opterećenje stanice. Korisnički podaci mogu sadržavati korisničke podatke o pretplati i vrsti uređaja korisnika. I vanjski podaci sadrže informacije specifične za korisnika dobivene iz različitih izvora kao što su senzori ili mjerni kanali [4]. Jedan od načina prikupljanja radijskih podataka je korištenje predmemorije gdje je ideja pohraniti popularne sadržaje na rub mreže (na baznim stanicama, uređajima ili drugim međulokacijama). U tom smislu, može se omogućiti proaktivni tip predmemorije ako algoritam učenja o prometu predviđa da će isti sadržaj biti zatražen u bliskoj budućnosti [5], [6]. Štoviše, budući da različiti korisnici mogu zahtijevati isti sadržaj s različitim kvalitetama, svaki rubni čvor treba pohraniti u predmemoriju isti sadržaj u različitoj granularnosti (na primjer, predmemoriranje video podataka s različitom rezolucijom). To

dodatno zahtijeva da rubni uređaj primjeni kodirane (adaptivne) tehnike predmemoriranja koje se temelje na zahtjev za kvalitetom usluge (engl. *Quality of Service*) podnositelja zahtjeva [14]. Kodirano predmemoriranje također omogućuje uređajima stvaranje mogućnosti *multicastinga* za određeni sadržaj putem kodiranih *multicast* prijenosa [7]. U nekim slučajevima, određeni rub može prikupiti datum iz više od jednog izvora s različitim kriterijima za povezivanje [8]. U radijskoj mreži s omogućenom maglom (engl. *Fog networking*) to je olakšano korištenjem IoT uređaja koji koriste razne tehnologije radio-pristupa kao što su radijske lokalne mreže (WLAN) i mobilne mreže.

Na slici broj 2. je prikazana tipična mreža sljedeće generacije koja usvaja načela AI uz učenje, razmišljanje i donošenje odluka



Slika 2: Tipična mreža sljedeće generacije koja usvaja načela AU uz učenje, razmišljanje i donošenje odluka

2.2. Otkrivanje znanja

Učinkovito otkrivanje znanja je ključno za optimiziranje rada i upravljanje mrežom. Mreža će morati koristiti novu tehniku učenja kao što je duboko učenje za izdvajanje skrivene kontekstualne informacije o mreži što je ključno za stvaranje baze znanja (engl. *Knowledge Base*). Općenito, kontekst je vezan za bilo koju informaciju koja se koristi za karakterizaciju situacija subjekta, uključujući okolnu lokaciju, identitet, preferencije i aktivnosti. Kontekst može utjecati na postupke rada i upravljanje složenim sustavima na različitim razinama, od fizičkog uređaja do razine komunikacije, pa do razine aplikacije [9]. Na primjer, otkrivanje odnosa između uređaja i podataka o mreži (korisnik, lokacija, brzina, razina baterije i aspekti višeg sloja) dopuštaju prilagodljivu komunikaciju i sposobnost obrade temeljene na promjenama u okruženju i aplikacijama [9]. Kontekstualno (semantičko) analiziranje radijskih podataka olakšava radijskim operaterima da optimiziraju promet na mreži. Da bi se realizirala optimizacija prometa svjesne semantike, mreža će morati razumjeti sadržaj signala. Jedan od načina razumijevanja informacijskog sadržaja podataka je stvaranjem semantički svjesnih ontologija koristeći unaprijed definirani rječnik pojmove i koncepta [10]. Ontološka specifikacija može pružiti izražajan jezik s mnogo logičkih konstrukcija za definiranje klasa, svojstava i njihovih odnosa. S tim u vezi, autori [10] predlažu semantički otvoreni model podataka za podatke senzora tzv. *MyOntoSens* i pišu koristeći ontološki web jezik tj. logički jezik opisa. Razumijevanje konteksta također pomaže u proizvodnji kontekstualno svjesne komprimirane (sažete) informacije koja će koristiti manje radio resursa za prijenos. Na primjer, ako bazna stanica želi prenijeti tekstualne informacije korisniku, bazna stanica može prenijeti samo svoje kontekstualno kodirane podatke. Korisnik će tada izdvojiti željeni sadržaj samo iz konteksta korištenjem odgovarajuće tehnike dekodera i analize velikih podataka kao što je NLP (engl. *Natural Language Processing*). Kako se kontekst razlikuje od svijeta korisnika znanje o sadržaju, tehnike kodiranja i dekodiranja tehnika se može razlikovati među korisnicima [9]. Općenito dvije vrste pristupa sažimanju sadržaja su uobičajeno usvojene; apstraktno i ekstraktivno. Ekstraktivnim pristupom koristi se samo relevantan sadržaj iz izvorne informacije, dok se apstraktnim pristupom može koristiti nove riječi (izraze ili sadržaje) kao dio sažetih informacija. Iako većina postojećih metoda može izvući korisne informacije za sažetak, jako su daleko od generiranja čovjeku razumljivog sažetka. Jedan od glavnih razloga su labave asocijacije i neuređena distribucija informacija.

3. USLUGE U 5G MREŽI

Intenzivna digitalizacija raznih gospodarskih grana predstavlja prvi korak prema uslugama 5G mreže, a taj će se proces u sve većoj mjeri nastaviti i u bliskoj budućnosti kako 5G mreža bude širom svijeta prihvaćena za novi globalni standard povezivosti. Ključ digitalizacije leži u načinima na kojima će različite industrije koristiti 5G za transformaciju poslovanja. Tako će razni poslovni sustavi koristiti dijelove mreže uskladene sa specifičnim zahtjevima svake industrije. 5G radio pristup, jezgrene mreže i upravljanje kompleksnim IT (engl. *Information Technology*) sustavima poduprijet će raznovrsne slučajeve korištenja ove tehnologije te nam omogućiti korištenje njenog punog potencijala. Od širokopojasne povezanosti u područjima s velikim brojem ljudi do udaljene automatizacije rada kritičnih strojeva u opasnim radnim okruženjima, poput rudnika, 5G već ima korisničke slučajeve koji mogu pomoći u poslovanju te su spremni za buduće potrebe. Među glavnim prednostima 5G tehnologije su sigurnost mreže i niska potrošnja energije što će poslovnim sustavima omogućiti efikasnu i troškovno učinkovitu digitalizaciju [7].

Usluge koje očekujemo u 5G mobilnoj mreži, su:

- Interakcija između čovjeka i Internet stvari (engl. *Internet of Things – IoT*) Doživljaj širokopojasnog pristupa bilo gdje i u bilo koje vrijeme
- Kritično upravljanje udaljenim uređajima
- Pametna vozila, transport i infrastruktura
- Medijski sadržaji bilo gdje

Interakcija između čovjeka i Internet stvari će povezivati korisnika 5G mreže sa stvarima poput računala, strojeva, raznih senzora i ostalih uređaja koji će biti spojeni na Internet. Usluga će biti namijenjena svim osobama u želji povećanja javne sigurnosti, zdravstvene skrbi i korištenja u svakodnevnom životu. Doživljaj širokopojasnog pristupa bilo gdje i u bilo koje vrijeme omogućit će pristup mobilnom Internetu pete generacije u napućenim područjima, javnom prijevozu i u slučaju velikog skupa ljudi na malom prostoru bez zagušenja. Omogućavat će visoku kvalitetu usluge u otvorenim i zatvorenim prostorima, kao i u zahtjevnim mrežnim uvjetima. Usluga će biti dostupna svim korisnicima mreže. Kritično upravljanje udaljenim uređajima će omogućiti korisniku usluge daljinskog upravljanja teškim strojevima, praćenja rada tvornica/procesa u realnom vremenu i slične usluge namijenjene sektoru proizvodnje, zdravstvene skrbi i radu u rudniku. Ova usluga povećava učinkovitost i smanjuje troškove te komunikacijske sabirnice zamjenjuje radijskim linkovima. Pametna vozila, transport i infrastruktura je usluga namijenjena autoindustriji u svrhu povezivanja i komunikacije između svih prijevoznih sredstava u cilju smanjena zagušenja prometa, uštede energije i povećanja sigurnosti u prometu. Usluga će koristiti senzore postavljene u cestama, željezničkim prugama i pistama koji će komunicirati međusobno s vozilima. Takav način komunikacije naziva se MTC (engl. *Machine Type Communication*). Medijski sadržaj bilo gdje je Cloud bazirana usluga koja će omogućavati korisniku pristup medijskom sadržaju na bilo kojem mjestu, u bilo koje vrijeme, uz pristup Internet vezi. Usluga

omogućava transformaciju industrije na „*all IP*“ (engl. *Internet Protocol*) te pruža korisniku vrhunsku video kvalitetu (4K, 8K, HDR (engl. *High Dynamic Range*), HFR (engl. *High Frame Rate*)) [7].

4. RAD I UPRAVLJANJE MREŽOM

Energetska i spektralna učinkovitost, latencija, pouzdanost i sigurnost su ključni parametri koji se uzimaju u obzir tijekom faze rada mreže. Pravilno optimiziranje ovih parametara obično daje zadovoljavajući učinak za pružatelja usluga i krajnje korisnike. Osim toga, parametri za optimizaciju obično zahtijevaju jednostavne algoritme za učenje i donošenje odluka u realnom vremenu.

4.1. Raspodjela i upravljanje resursima

Predlažu se različite AI tehnike za raspodjela resursa, upravljanje i optimizaciju radijske mreže kao što su mobilne, nosive, *WSN* i mreža područja tijela *BAN* (engl. *Body Area Network*) . U [11], razmatran je potencijal AI u rješavanju problema alokacije kanala u radijskoj komunikaciji. Dokazano je da je pristup temeljen na umjetnoj inteligenciji pokazao bolje performanse od slučajnih heurističkih i genetskih algoritama (engl. *Genetic algorithms*). U [12], predlaže se radio pristup tehnologija (engl. *Radio Access Technology*) koja koristi Hopfieldove neuronske mreže kao alat za donošenje odluka uz iskorištavanje sposobnosti AI zaključivanja i upotrebe više-parametarskih odluka iskorištavanjem opcija koje se nude kroz protokol IEEE 802.21. Tehnike bazirane na strojnom učenju, uključujući nadzirane, nenadzirane i tehnike učenja, se koriste za usmjeravanje paketa u različitim mrežnim scenarijima [13]. Tehnikom dubokog učenja se planira promijeniti računalne potrebe s rute temeljene na pravilima računanja (engl. *rule-based*) do rute temeljene na procjeni strojnog učenja (engl. *machine learning-based*) za obradu paketa velike propusnosti što je predloženo u [13]. Mreža s radio pristupom temeljena na magla računanju koja iskorištava prednost lokalne obrade radio signala, kooperativno upravljanje radio resursima i distribuiranu pohranu magle se preporučuje da smanji opterećenje i izbjegne obrada radio signala velikih razmjera u centraliziranim kontrolerima osnovnog pojasa. Korištenjem nelicenciranih spektara kao dopunu licenciranim, dobiva se rasterećenje mrežnog prometa putem agregacije nositelja okvira, dok će se kontrolni signali, glasovni i kontrolni podaci uvijek prenositi na licenciranom spektru.

4.2. Sigurnost i zaštita privatnosti

Urođena zajednička priroda radio-propagacije okruženja čini radijski prijenos ranjivim na zlonamjerne napade, uključujući prisluškivanje i ometanje. Iz tog razloga sigurnost i zaštita privatnosti su temeljne brige današnjice za radijske komunikacijske sustave. Radijske mreže općenito usvajaju zasebne razine sigurnosti na različitim slojevima stoga komunikacijskih protokola. Nadalje, različite aplikacije obično zahtijevaju različite metode šifriranja [20]. Korištenje AI tehnika za radijsku sigurnost su doobile značajan interes.

Stjecanje podataka i otkrivanje znanja
<ul style="list-style-type: none">• Kontekstno svjesno prikupljanje podataka iz jednog/više izvora• Kodirano (prilagodljivo) <i>cacheiranje</i>• Semantički svjesna ontologija (<i>KB</i>) stvaranje iz mrežnih podataka• Robusno otkrivanje znanja iz pogrešnih (nedostajućih) podataka
Planiranje mreže
<ul style="list-style-type: none">• Rasporedjivanje čvora i dodjela radio frekvencija• Predmemorija i računanje položaja i ažuriranja sadržaja• Modeliranje i predviđanje potrošnje energije (u mirovanju/aktivno)• Postupak konfiguracije parametara i usluge
Rad i upravljanje mrežom
<ul style="list-style-type: none">• Raspodjela resursa: <i>RAT</i> i odabir kanala, usmjeravanje paketa, distribuirana pohrana i obrada, raspoređivanje više <i>RAT</i> paketa• Sigurnost: Lažni napadi i otkrivanje upada• Latencija: Kontekstno svjesno rubno računanje i zakazivanje

Tablica 1. Glavni problemi u radijskoj mreži s AI-om

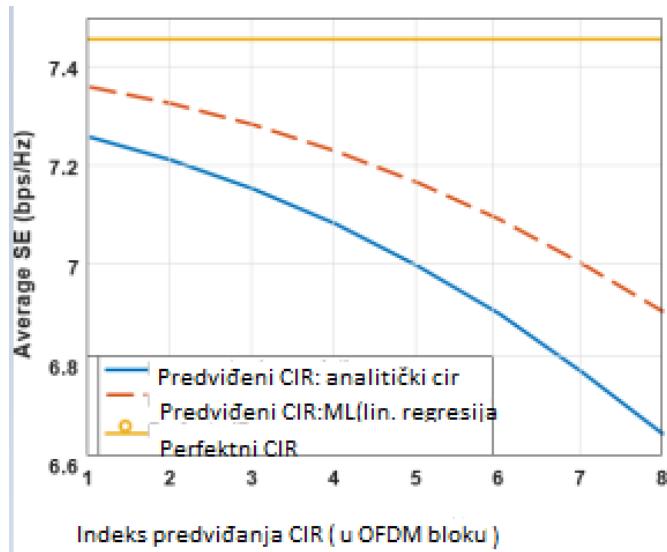
U [17], shema za otkrivanje napada lažiranja koristeći raspodjelu slučajnog ključa predložen je sustav umjetno imuni sistem (engl. *Artificial Immune system AIS*). Na sličan način, pristup temeljen na GA (engl. *Genetic Algorithms*) i *AIS*-u, nazvan GAAIS, za dinamičko otkrivanje upada u mobilne *ad-hoc* mreže (*MANETs*) sugerira se u [19]. U [18] je razvijeno napredno otkrivanje upada u senzorske mreže (*ADIOS*). One su dizajnirane da ublaže napad za zabranu usluge (engl. *denial-of-service*) u radijskim senzorskim mrežama tako što će uhvatiti i analizirati događaje na mreži koristeći AI i ekspertne sustave razvijene u programskom jeziku C. U sličnom djelu, autori [32] predlažu shemu temeljenu na umjetnoj inteligenciji da osiguraju komunikacijski protokol povezanih vozila.

4.3. Optimizacija kašnjenja za taktilne aplikacije

Radijske mreže sljedeće generacije sadržavaju nekoliko kritičnih (taktilnih) aplikacija kao što su mijenjanje trake u automatiziranim vozilima. Za vozila na mreži, različite razine automatizacije su definirane od strane Ministarstva prometa SAD-a u rasponu od jednostavne

pomoći vozaču (razina 1) do potpune automatizacije (razina 5). Za ovu aplikaciju, može se primijeniti različiti sustav poruka uključujući alarm upozorenja te slikovne i audio informacije prilikom zahtjeva za intervencijom. Zapravo, nedavno je dokazano eksperimentom da se od nepreciznih podataka korištenjem tehnika prirodnog jezika poboljšava točnost ljudskih odluka. Takav lingvistički opis podataka mogao bi biti dizajniran modeliranjem nejasnih izraza kao što su mali i veliki, koje su norme u svakodnevnom životu razgovora, korištenjem teorije neizrazite logike [21]. Sve ovo olakšava korištenje prediktivnog strojnog učenja.

Na slici broj 3. je prikazana usporedba analitičkog i strojnog učenja ML (engl. *Machine Learning*) pristupi u smislu postignutog prosječnog SE (engl. *Spectrum efficiency*) za drugačiji budući OFDM (engl. *Orthogonal Frequency Domain*) blok indeks CIR (engl. *Committed Information Rate*)



Slika 3: Usporedba analitičkog i strojnog učenja (ML) pristupi u smislu postignutog prosječnog SE za drugačiji budući OFDM blok indeks CIR

S računalne strane, rubni uređaji se mogu koristiti za učinkovite nisko latentne izračune, koristeći nove paradigme mobilnog rubnog izračuna. Međutim, optimiziranje mobilnog rubnog izračuna se suočava s mnogo izazova kao što je postavljanje računala, raspodjela računskih resursa, računalni zadatak dodjela, *end-to-end* latencija i potrošnja energije. U tom smislu, tehnika strojnog učenja se može koristiti za rješavanje ovih izazova korištenjem povijesnih podataka. Predviđanje računskog zahtjeva omogućuju mrežnim uređajima zakazivanje računskih resursa unaprijed da se minimizira globalna latencija. U tom smislu, autori [16] predlažu okvir za učenje među sustavima kako bi se optimizirale dugoročne performanse *multi-mode* baznih stanica, usmjeravanjem prometa tolerantnog na kašnjenje prema *Wi-Fi-ju*. Nadalje, u radijskom sustavu s omogućenom maglom, latencija može se riješiti iskorištavanjem različitih razina svijesti na svakoj rubnoj mreži. Zapravo, veći broj tehnika za učenje se može primijeniti da bi se postigla ta razina svijesti uključujući inkrementalnu, zavadi pa vladaj, paralelno i hijerarhijski [5]. Kratak sažetak o različitim problemima u radijskoj mreži s AI-om je prikazan u tablici 1.

5. STUDIJE SLUČAJA DIZAJNA

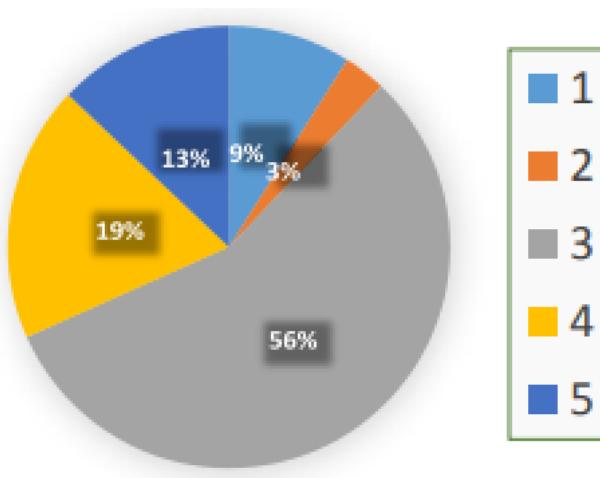
Za svakog korisnika najvažnija je kvaliteta primljene usluge, neovisno da li se radi o glasovnoj, podatkovnoj ili video usluzi. Korisnik ne može znati koliko se paketa izgubilo pri prijenosu, koliko je kašnjenje te kolika je širina prijenosnog pojasa. Imamo dvije metode za mjerjenje kvalitete usluge, a to su subjektivna i objektivna. Kod subjektivne metode određenom broju korisnika pušta se zvuk ili video kroz određeno vrijeme. Nakon određenog vremena korisnik daje ocjenu kvalitete s kojom je bio zadovoljan. Objektivna metoda kvalitete usluge dobiva se mjeranjem fizičkih osobina mreže. Određuje se postotak izgubljenih paketa, vrijeme kašnjenja i kolebanja kašnjenja te potrebna propusnost za pojedinu uslugu.

5.1. Subjektivna metoda

Ova studija pokazuje korištenje alata za strojno učenje za optimizaciju resursa radijskog sustava. U tom smislu odabiremo radijski *CIR* predviđanje kao cilj dizajna. Za objektivno postizanje cilja ovoga dizajna, prva bi mogućnost mogla biti primjena različite analitičke tehnike predviđanja *CIR-a* (na primjer, za rekurzivno predviđanje najmanjeg kvadrata RLS (engl. *Least Square Prediction*) predloženo u [22]). Druga mogućnost bi mogla biti predviđanje budućeg *CIR-a* korištenjem prošlih iskustava. Prva mogućnost je posebno skupa kada je potrebno predviđanje u stvarnom vremenu. Nadalje, u većini slučajeva, pristup analitičkog predviđanja može propasti kad god postoji greška u modeliranju ili nesigurnost. Potonja je mogućnost, međutim, jednostavna jer koristi prošlo iskustvo i primjenjuje standardno množenje vektora i operacije zbrajanja [23]. Ova simulacija uspoređuje izvedbe RLS-a i pristupa predviđanja strojnim jezikom. Za strojno učenje, koristimo dobro poznatu multivarijatnu linearu regresiju. Za usporedbu uzimamo ortogonalni prijenos multipleksiranja frekvencijske domene OFDM (engl. *Orthogonal Frequency Domain Multiplexing*). Shemu gdje je bazna stanica opremljena s N antena opslužuje jednog *IoT* uređaja s jednom antenom. *CIR* je modeliran razmatranjem tipičnog scenarija IEEE 802.11 standarda s korelacijom kanala prostorno i privremeno. Kovarijantna matrica prostornog kanala modelira se razmatranjem strukture uniformnog linearog niza ULA (engl. Uniform Linear Array) i vremenska korelacija kanala je dizajnirana prema poznatom *Jakeovom* modelu [33].

Broj višestaznih slavina $L = 4$, brza *Fourier* transformacija (FFT) veličina $M = 64$, $N = 8$, OFDM simbol period $T_s = 166 \mu\text{s}$, veličina RLS prozora $S_b = 8$, veličina prozora predviđanja $S_f = 8$, frekvencija nosioca 5,6 GHz i brzinu mobilnosti *IoT* uređaja 30 km/h. Omjer signala i šuma *SNR* (engl. *Signal-to-Noise Ratio*) za svaki podnosač je postavljen na 10 dB. S ovim postavkama, slika 4 pokazuje dobivenu prosječnu učinkovitost spektra *SE* (engl. *Spectrum Efficiency*) dobiven *RLS-om* i pristupima strojnog učenja za podnosač $s = 4$. U oba slučaja postignuti *SE* se smanjuje kako se budući indeks *OFDM* bloka povećava. To je očekivano jer broj nepoznatih *CIR* koeficijenti raste kako se budući blok indeks povećava što dovodi do smanjene kvalitete predviđanja *CIR-a*. Međutim, za fiksni indeks predviđanja budućnosti, strojni pristup učenju daje bolje rezultate od *RLS-a*.

Na slici broj 4. je prikazan Promet podataka uzorka apstraktne informacije



Slika 4: Promet podataka uzorka apstraktne informacije

5.2. Objektivna metoda

Kontekstno (semantički) svjestan prijenos informacija je ključan u mreži buduće generacije. Za provjeru valjanosti pri tome koristimo apstraktne tekstove iz znanstvenih članaka [24]. Prema ovom radu, svaki znanstveni apstraktni tekst se sastoji od različitih vrsta informacija uključujući pozadinu istraživanja, metodologiju, glavne rezultate itd. Slika 5 prikazuje veličinu podataka s komentarima stručnjaka za različite vrste za 2000 sažetaka biomedicinskih članaka. Kao što se može vidjeti iz ove slike, različiti tipovi informacija koriste različite dijelove ukupnog skupa podataka. I za zadanog korisnika može se prenijeti željena informacija prema sadržaju. Na primjer, za korisnika koji je zainteresirani za osnove članka, prenoseći pozadinske informacije moglo bi biti dovoljne što se odnosi na samo 9% ukupnog prometa. Ovo pokazuje da će semantički omogućen prijenos podataka smanjiti mrežni promet uz istovremeno održavanje željenog *QoS* iskustva korisnika.

Takav prijenos se, međutim, ostvaruje kada su rečenice sličnih tipova pravilno grupirane za svaki sažetak. U znanstvenim radovima, mjesto i dio-govorni glas rečenice ključne su značajke za identificirati njegov skup klasa [24]. Kao što se može vidjeti iz tablice 2, različiti algoritmi *klasteriranja* daju različite točnost. Iz ove se tablice također može primijetiti da će se vjerojatno trebati poduzeti značajan istraživački rad da bi se postigla idealna izvedba.

Tablica 2. Točnost različitih metoda grupiranja

Metoda klasteriranja	Postavi 1	Postavi 2	Postavi 3	Postavi 4	Postavi 5

K-značenje	0.34	0.17	0.35	0.31	0.16
Aglomerativno	0.21	0.18	0.38	0.30	0.15

6. POZADINA STROJNOG UČENJA

Tijekom proteklog desetljeća, ogroman rast podataka širom mnogih različitih područja rezultirala su izazovom velikih podataka koji pojačava potrebu za inteligentnim shemama analize podataka. Pojavile su se različite metode strojnog učenja, poput dubokog učenja, a korišteni su zajedno s tradicionalnim metodama strojnog učenja za rješavanje problema velikih podataka. Nedavno su ugrađeni u radijskim mrežama. Stoga u ovom odjeljku dajemo kratak pregled široko korištenih tehnika. Sheme strojnog učenja mogu se podijeliti u četiri glavne kategorije: učenje pod nadzorom, učenje bez nadzora, nadzirano učenje i učenje s pojačanjem. Ove četiri kategorije razlikuju se po načinu na koji su algoritam postoji postavljeni [1]. U nadziranom učenju u početku se izvodi obuka s nekim označenim podacima. Označeni podaci predstavljaju skup unaprijed poznatih ulaza s njihovim odgovarajućim izlazima. Stoga su algoritmi učenja pod nadzorom prikladni aplikacijama s povijesnim podacima. Značajka ekstrakcija i klasifikacija primijenjena je na nekoliko problema s obradom signala. Zadatak klasifikacije je identificirati kojem skupu kategorija pripada novo opažanje. Nasuprot tome, algoritmi učenja bez nadzora nastoje zaključiti značajke u podacima, čime se zaključuje podrazumijevana struktura. Algoritmi za polunadzirano učenje koriste i označene i neoznačene podatke. Konačno, učenje s pojačanjem koristi podatke iz implementacije umjesto povijesnih podataka.

Cilj učenja s pojačanjem je poboljšati izvedbu jednog agenta u određenom zadatku koristeći povratne informacije iz okoline. Kao takav, cilj agenta je predvidjeti sljedeću radnju koju treba poduzeti da zaradi najveću konačnu nagradu. Učenje s pojačanjem je bez nadzora međutim način učenja je drugačiji od drugih tehnika učenja bez nadzora. Umjesto učenja strukture nekih podataka, učenje s pojačanjem pokušava istražiti najbolje akcije u mediju rada. Stoga, sposobnost hvatanja okoline putem povratnih informacija i obavljanje radnji čini učenje s pojačanjem prikladnim za probleme koji uključuju niz odluka, npr. slijedenje skupa akcija u promatranom stanju okoliša. Pojačano učenje može biti bazirano na modelu ili bez modela. U učenju baziranom na modelu agent cilja će razumjeti okolinu i na temelju toga napraviti model. U učenju bez modela nastoji se naučiti skup pravila koja će se platiti. Učenje bez modela prikladnije je za radijske mreže budući da se učenje iz povijesti ne poklapa dobro s dinamikom mreža. Q-učenje je primjer algoritma učenja bez modela koji ima za cilj naučiti pravila koja agentu govori koju radnju treba poduzeti u svakom stanu. Drugim riječima, Q-učenje pruža agentu sposobnost učenja najboljih radnji u svakom stanu bez znanja vjerojatnosti prijelaza modela. Slika 5 predstavlja konceptualni dijagram Q-učenja. Agent počinje odabriom radnje prema skupu pravila. Nakon izvršenja radnje, okolina će biti pod utjecajem i neke povratne informacije se vraćaju agentu. U radijskim mrežama povratna informacija može biti smetnja ili stanje čekanja čvorova ili zagušenje puta ili akcije učenja drugih čvorova i mnogih drugih čimbenika. Stoga povratne informacije mogu biti izračunate na strani agenta, kao što je mjerjenje omjera signala i smetnje. Agenti također mogu razmjenjivati njihove odluke kao oblik povratne informacije jedni drugima. Ovo posljednje

postavlja komunikacijske troškove jer više mrežnih resursa mora biti dodijeljeno kako bi se olakšalo signaliziranje među agentima. Povratne informacije će modificirati nagradu i agent će promatrati novo stanje. Vrijednosti stanja, djelovanja i nagrade koje su dobiveni, karakteriziraju kvalitetu poduzete radnje u trenutnom stanju, stoga agenti pohranjuju ovu vrijednost kvalitete (tj. Q-vrijednost) u Q-tablici. Ponavljanim istraživanjima različitih radnji u različitim stanjima, agent će moći identificirati optimalne radnje koje treba poduzeti. Izvodi se ažuriranje Q-vrijednosti iterativno korištenjem jednadžbe ažuriranja Q-učenja kako slijedi [1]:

$$Q(s, a) \leftarrow (1 - \alpha)Q(s, a) + \alpha[R(s, a) + \gamma \max(1)AQ(s, a)] \quad (1)$$

gdje je α stopa učenja, γ diskontni faktor, $R(s, a)$ je nagrada u paru stanje-akcija (s, a) , a $Q(s, a)$ je Q-vrijednost para stanje-akcija (s, a) . Osim Q-učenja, odnedavno se koristi i neuronska mreža.

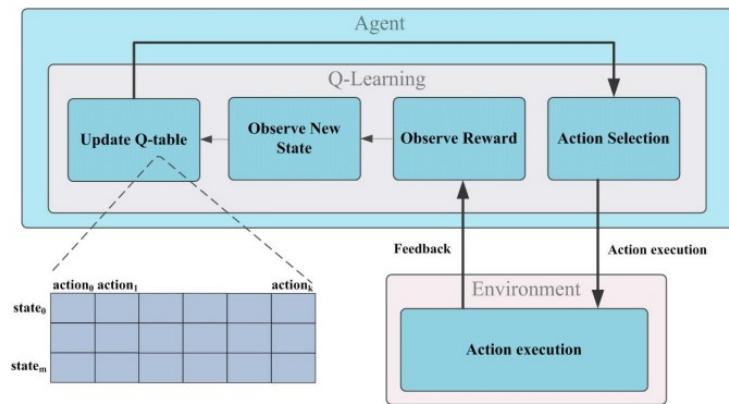
Koristi se u najsuvremenijim istraživanjima radijskih mreža. Neuronske mreže su dizajnirane da oponašaju strukturu neurona u ljudskom mozgu. Konkretno, neuronska mreža se sastoji od tri vrste slojeva: ulazni sloj, izlazni sloj i skriveni slojevi. Svaki sloj se sastoji od skupa umjetnih neurona koji obavljaju određenu matematičku funkciju, specifičnu neuron aktivacijsku funkciju. Neuroni u određenom sloju su povezani neuronima u prethodnom sloju, gdje je svaka veza ima težinu. U fazi treninga težina se prilagođava prema skupu podataka o obuci.

Skup podataka za obuku pruža skup ulaza i očekivanih izlaza. Neuronske mreže mogu biti strukturirane u različitim oblicima kao što su *feedforward*, konvolucija ili rekurentna neuronska mreža. Neuronska mreža s jednim skrivenim slojem je plitka neuronska mreža, dok je neuronska mreža s više skrivenih slojeva duboka neuronska mreža. Nadalje, duboke neuronske mreže mogu imati različite oblike kao što su *feedforward*, konvolucija ili rekurentna. Slika 6 predstavlja primjer duboke *feedforward* neuronske mreže gdje informacije idu u jednom smjeru. Nasuprot tome, duboko rekurentna neuronska mreža uključuje povratne veze među slojevima. Takva povratna informacija omogućuje dubokoj rekurentnoj neuralnoj mreži zaključivanje odnosa u dugim sekvenčijalnim informacijama (tj. učinkovitiji u generalizaciji). Novija metoda koju je razvio *Google DeepMind* je duboko Q-učenje [2]. Za razliku od tradicionalnih tabličnih Q-učenja, duboko Q-učenje nadopunjuje Q-učenje algoritmom s dubokom konvolucijskom neuronskom mrežom, koja aproksimira funkciju Q-vrijednosti, izbjegavajući potrebu za pohranom ogromnih količina informacija. Slika 7 predstavlja komponente dubokog učenja s pojačanjem kako je predložio *Google DeepMind* [2].

Duboko učenje s pojačanjem uključuje Q-učenje, neuronsku mrežu i iskustvo ponavljanja memorije. Algoritam Q-učenja je sličan algoritmu prikazan na slici 5 nakon uklanjanja Q-tablice. Kao takav, Q-učenje vrši odabir radnji, izračun nagrade, i promatranje novog stanja kao prije, što se označava kao Iskustvo Q-učenja $e =$ staro stanje (s) , staro djelovanje (a) , nagrada (rc) od starog stanje-akcija, novo stanje (s') . Odabir akcije je izведен korištenjem pravila Q-učenja koja se primjenjuju na Q-vrijednosti procijenjeno neuronskom mrežom. Trening neuronske mreže se izvodi korištenjem iskustava iz algoritma Q-učenja gdje se uzorci za obuku izvlače iz Memorija ponovne reprodukcije koja pohranjuje iskustva preko mnogih epizoda. Ugradnja duboke neuronske mreže omogućila je pojačano učenje tako da riješi probleme koji su bili prije nerješivi.

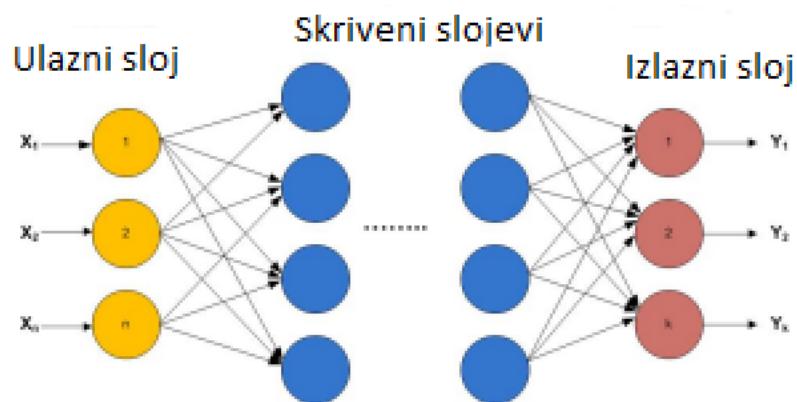
Ti problemi imaju prostor visoke dimenzije koji vodi do problema prokletstva dimenzionalnosti što bi moglo uzrokovati sporo ponašanje konvergencije. Duboka neuronska mreža djeluje kao aproksimator funkcije, gdje umjesto procjene jedne Q-vrijednosti svake iteracije, predviđa Q-vrijednosti pojedinačnih radnji za dano ulazno stanje sa samo jednim prolazom.

Na slici broj 5. je prikazan konceptualni dijagram rada Q-učenja



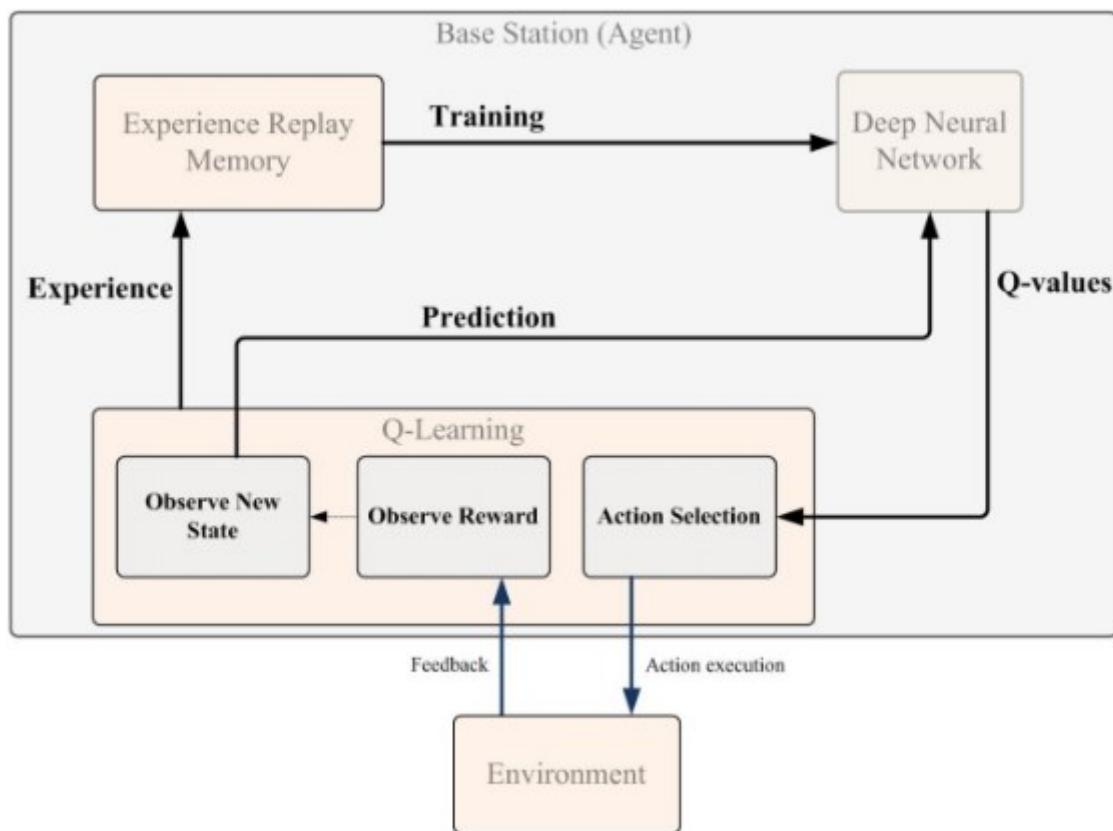
Slika 5: Konceptualni dijagram rada Q-učenja

Na slici broj 6. je prikazana tipična struktura neuronske mreže



Slika 6: Tipična struktura neuronske mreže

Na slici broj 7. je prikazana arhitektura dubokog Q-učenja



Slika 7: Arhitektura dubokog Q-učenja

7. ČOVJEK PROTIV STROJA

Vječna dilema koja zaokuplja suvremene istraživače, i ne samo njih nego i psihologe, pedagoge, inženjere i općenito znanstvenu javnost... gdje je granica, koji su to parametri koji će pokazati kada je stroj superioran i kada je čovjek nezamjenjiv. Jer se zapravo u razvoju umjetne inteligencije također vode polemike u kojem pravcu istraživanja trebaju ići. Neki smatraju da umjetna inteligencija ne treba natjecanje s čovjekom, nego da se razvija u smjeru da što kvalitetnije opslužuje zahtjeve koji se postave pred njih. S druge strane dio znanstvenika smatra da u stopostotnom postotku računalo može biti intelligentno, samo mu treba upravljački softver koji je dovoljno intelligentan. U toj nekoj dilemi oko granice, što je čovjek a što stroj, puno pomaže primjer koji nam zaista u nekim stvarima otvara prostor za nedoumice da li razgovaramo s čovjekom ili s programom. Primjer definira da čovjek treba vršiti korespondenciju s nekim, pri tome ne zna s kim, a s druge strane je nekad čovjek nekad program. Cilj je da čovjek ne prepozna s kim komunicira. Alan Turing utemeljio je taj test i po njegovom imenu se taj test zove Turingov test. Naravno postavio je i protokole za provođenje testa, a oni su zapravo, da se komunikacija vrši putem poruka na papiru. Kao rezultat tog otkrića pokrenula se lavina istraživanja u obliku pisanja programa koji mogu odgovoriti tim zahtjevima. A za spomenuti je hvale vrijedan projekt koji je pokrenuo Joseph Weizenbaum. On je 1964. napisao računalni program pod nazivom Eliza koji je bio osmišljen tako da oponaša psihoterapeuta. Rezultat je iznenadio sve pa tako i same korisnike koji su zapravo u potpunosti mislili da razgovaraju s pravim psihoterapeutom, jer je algoritam imao mogućnost da iz postavljenih pitanja izvlači odgovore i time pospješuje komunikaciju ili ako ne bi imao odgovor rješenje mu je bilo da postavi neko suvislo pitanje koje je vezano za pređašnji razgovor i time otvorio novo područje komunikacije. Čak su neki sudionici bili potpuno uvjereni da se radi o čovjeku i nastavljali duge razgovore neovisno o problemu koji je bio predmet istraživanja uspješnosti umjetne inteligencije.[29]

8. POJAM UMJETNE INTELIGENCIJE

Mnogo je polemike oko pojma umjetne inteligencije. Svaki čovjek zapravo analizirajući pojam umjetne inteligencije doživljava to kao zamjenu za neke obveze koje bi mu omogućile lakši život. I to sve izgleda jednostavno, no kada se ozbiljnije pristupi problemu vidi se sva kompleksnost pojma umjetne inteligencije. Postoje mnoge teorije o tome sto je zapravo umjetna inteligencija pa tako: "Umjetna inteligencija propituje jednu od konačnih zagonetki. Kako je moguće da spor, maleni mozak, biološki ili elektronički, može percipirati, razumjeti i predviđati svijet, te manipulirati svijetom mnogo većim i mnogo kompleksnijim nego što je on? Kako da izgradimo nešto s takvim svojstvima? Ta su pitanja teška, ali, za razliku od putovanja brzinom većom od brzine svjetlosti ili anti-gravitacijskog uređaja, istraživač na području umjetne inteligencije ima čvrste dokaze da je moguće ostvariti. Sve što trebamo učiniti je pogledati u zrcalo da bismo vidjeli primjer intelligentnog sustava" (Norvig i Russell, 1995, str 3). Ili pak: Umjetna inteligencija, jest sposobnost digitalnog računala ili računalno kontroliranog robota da izvodi zadaće obično povezane uz intelligentna bića. (Copeland, 2014) Sve to zapravo ukazuje na to da je bitno da se uz pomoć određenog nadzora –upravljanja , a to je najčešće digitalno računalo, omogući izvršavanje odnosno donošenja odluke u zadanim uvjetima i na određeni način: što odlikuje intelligentna bića. To implicira da se mogućnost nekog objekta, stroja dovede u stanje da zapravo bilježi i prikuplja podatke i da na osnovi tih podataka-znanja uz određene parametre doneše neku odluku ili radnju koja će pak imati svrsishodnu reakciju odnosno rezultat, a to također mora biti upamćeno i primjenjivo u nekoj drugoj situaciji. Zapravo to je mogućnost učenja. Velike su prepirke oko moralnog aspekta te mogućnosti, ali bez obzira na to umjetna inteligencija je nezamjenjiva komponenta budućeg društva, ne samo industrije. Navikli smo zapravo da se pametni strojevi-roboti uključuju u industrijske pogone i time zamjenjuju ljudsku radnu snagu, ali smo također svjedoci da se pametni strojevi uvode i u druge društvene djelatnosti poput nedavno pisanja novinskog članka kojeg je pisao robot, a ne novinar. No, kada se želi zauzeti generalan stav o tome što je zapravo umjetna inteligencija, mnogi se razilaze u razmišljanjima i konceptima pristupa u istraživanju, što zapravo umjetna inteligencija treba ispuniti.

Razvoj umjetne inteligencije seže u tridesete godine prošlog stoljeća, što zapravo govori o težnji čovjeka da istražuje područja u kojima bi ga se zamijenilo u mnogim poslovima. Kako se razvijala računalna tehnologija, time se i povećavaju zahtjevi za sve većom potrebom u zamjeni ljudi strojevima u svakidašnjem životu. Pedesetih godina počinje ozbiljnije vrijeme za umjetnu inteligenciju i tada se počinju stvarati akademije koje su se uhvatile u koštac s određivanjem pravaca istraživanja. Od tih godina pa sve do danas razvile su se mnoge škole i teorije o umjetnoj inteligenciji, ali ove tri su značajne za istaknuti: kognitivistička škola, logička škola i bihevioristička škola. U međuvremenu se šezdesetih i sedamdesetih godina prošlog stoljeća zbog određenog pristupa u hijerarhiji izgradnje umjetne inteligencije, a ona se odnosila na izgradnju jednog objekta s različitim komponentama koji su imali svoje module za obradu ulaznih podataka, što je za posljedicu imalo da ti moduli opslužuju sve veći broj apstraktnih ideja. Takva struktura objekta koji je trebao djelovati kao jedan entitet bila je neostvariva i dovela do jednog perioda u razvoju umjetne inteligencije koji se popularno naziva i „zima umjetne inteligencije“. U to

vrijeme se jako smanjilo ulaganje u razvoj AI a time je i interes razvojnih inženjera pala. To je vrijeme osamdesetih godina prošlog stoljeća. I zapravo cijelo to vrijeme koje je proteklo sve do pojave softvera koji su zapravo bili orijentirani sintezi postojećih znanja nije se značajno ništa dogodilo što je davalо smjer istraživanja.[30]

9. RAZVOJ UMJETNE INTELIGENCIJE U 5G MREŽAMA

Najnovija tehnologija peta generacija mobilnih standarda ili 5G nakon eksperimentalne primjene započela je svoje komercijalno korištenje na nekoliko odabranih lokacija u svijetu. U Europi je to švicarski telekom operater Swisscom koji je na Ericsson tehnologiji uspostavio svoju 5G mrežu. Već na samom početku komercijalne primjene 5G tehnologije donosi značajan napredak u odnosu na 4G. Prve 5G komercijalne mreže ostvaruju brzine do 600 Mb/s ali imaju potencijal i znatno bržeg prijenosa podataka, do čak 1 terabajta (Tb). 4G mreže općenito rade na 28 Mb/s. 5G će svojim brzinama biti i zamjena za mnoge fiksne mreže temeljene na optičkim nitima. Prednost je i što 5G bazne stanice mogu obrađivati i do milijun veza odjedanput, nasuprot 4G baznim stanicama koje su ograničene na 4.000 veza u isto vrijeme. Takva prednost dolazit će do izražaja, na primjer, na velikim skupovima, poput koncerata, sportskih događanja pa do mogućnosti realiziranja interneta stvari.

Dodatna prednost je što je 5G dizajniran tako da ima latenciju od samo jedne milisekunde, u usporedbi s 50 milisekundi ili više u 4G tehnologiji. Skraćivanje čekanja omogućuje, na primjer, preciznije kontroliranje bespilotnih letjelica, pa čak i obavljanje tele operacija pomoću mobilne veze. Među ostalim prednostima očekuje se kako će baterije za 5G uređaje imati mogućnost 10 puta većeg kapaciteta od uređaja namijenjenih 4G mrežama.

Uz značajne prednosti novih 5G mreža jasno je kako će razvoj komunikacija i interneta stvari dovesti do potrebe daljnog unaprjeđenja komunikacijskih mogućnosti, odnosno do naprednije tehnologije koja se uvjetno može nazvati 6G. U čemu će biti taj napredak je pitanje o kojem su već svoja razmišljanja iznijeli Razvan-Andrei Stoica i Giuseppe Abreu s Jacobs University-a Bremen u Njemačkoj. Pokušavajući analizirati ograničenja 5G tehnologije ta dvojica stručnjaka smatraju kako se ona mogu prevladati primjenom umjetne inteligencije u mreži, odnosno da će primjena umjetne inteligencije omogućiti potpuno novu generaciju komunikacijske tehnologije.

Na primjer, kod interneta stvari u 5G mrežama problem može nastati kod koordinacije autonomnih vozila koji prometuju u najvećim gradovima. U New Yorku sada prometuje 2,7 milijuna vozila svaki dan. Pri autonomnoj vožnji od sigurnosnog je značenja da vozilo ima potpune informacije o svom položaju, objektima u okolini, informacije o drugim vozilima, pješacima, biciklistima, radi sigurnije i učinkovitije vožnje potrebni su mu i podaci o gustoći prometa u ulicama u gradu kroz koje će prometovati kako bi optimizirao vožnju i skratio vrijeme putovanja. Interakcije u internetu stvari će zahtijevati masovnu obradu podataka. Količina podataka u mrežama će značajno rasti pa će trebati iznaći rješenja za njihovu dostupnost ali i kolaborativnu obradu u stvarnom vremenu. Razvan-Andrei Stoica i Giuseppe Abreu ističu kako je jasno da će umjetna inteligencija imati važnu ulogu u izgradnji novih naprednijih komunikacijskih mreža. Priroda takvih komunikacija morat će biti radijska.[31]

10. ZAKLJUČAK

Radijske mreže sljedeće generacije, koje će biti više dinamične, složene s gustim rasporedom BS-ova različite vrste i pristupne tehnologije, predstavljaju mnoge izazove dizajna za mrežno planiranje, upravljanje i postupcima za rješavanje problema. Ipak, radijski podaci se mogu generirati iz različitih izvora, uključujući umreženi informacijski sustav, te senzorske i komunikacijske uređaje. Nadalje, nastajanje magla računalne arhitekture s ciljem distribuiranog računalstva, pohrane, kontrole, komunikacije i mrežne funkcije bliže krajnjim korisnicima doprinose učinkovitom realizacijom radijskih sustava. To pruža opsežnu anketu o korištenju AI koji integrira strojno učenje, analizu podataka i *NLP* tehnike za povećanje učinkovitosti radijske mreže. Dao sam sveobuhvatnu raspravu o korištenju ovih tehnika za učinkovito radijsko prikupljanje podataka i znanja, otkrivanje, planiranje, rad i upravljanje sljedećim generacijama radijskih mreža.

LITERATURA

- [1] X. Wang and Y. He, "Learning from uncertainty for big data: Future analytical challenges and strategies," IEEE Systems, Man, and Cybernetics Magazine, vol. 2, no. 2, pp. 26-31, April 2016.
- [2] Ruilong Deng, Rongxing Lu, Chengzhe Lai, Tom H Luan, and Hao Liang, "Optimal workload allocation in fog-cloud computing toward balanced delay and power consumption," IEEE Internet of Things Journal, vol. 3, no. 6, pp.1171-1181, 2016.
- [3] J. Prez-Romero, O. Sallent, R. Ferrs, and R. Agust, "Knowledge-based 5G radio access network planning and optimization," in 2016 International Symposium on Wireless Communication Systems (ISWCS), Sept 2016, pp. 359-365.
- [4] J. Prez-Romero, O. Sallent, R. Ferrs, and R. Agust, "Artificial intelligence-based 5G network capacity planning and operation," in 2015 International Symposium on Wireless Communication Systems (ISWCS), Aug 2015, pp. 246-250.
- [5] E. Bastug, M. Bennis, and M. Debbah, "Living on the edge: The role of proactive caching in 5G wireless networks," IEEE Communications Magazine, vol. 52, no. 8, pp. 82-89, Aug 2014.
- [6] E. Bastug, M. Bennis, M. Medard, and M. Debbah, "Toward interconnected virtual reality: Opportunities, challenges, and enablers," IEEE Communications Magazine, vol. 55, no. 6, pp. 110-117, 2017.
- [7] Y. Fadlallah, A. M. Tulino, D. Barone, G. Vettigli, J. Llorca, and J.M. Gorce, "Coding for caching in 5G networks," IEEE Commun. Magazine, vol. 55, no. 2, pp. 106-113, 2017.
- [8] D. Ohmann, A. Awada, I. Viering, M. Simsek, and G.P. Fettweis, "Achieving high availability in wireless networks by inter-frequency multi-connectivity," in 2016 IEEE International Conference on Communications (ICC), May 2016, pp. 1-7.
- [9] F. Chiti, R. Fantacci, M. Loreti, and R. Pugliese, "Context-aware wireless mobile autonomic computing and communications: Research trends and emerging applications," IEEE Wireless Commun., vol. 23, no. 2, pp. 86-92, Apr. 2016.
- [10] L. Nachabe, M. Girod-Genet, and B. El Hassan, "Unified data model for wireless sensor network," IEEE Sensors Journal, vol. 15, no. 7, pp. 3657-3667, July 2015.
- [11] S. I. Suliman, G. Kendall, and I. Musician, "Artificial immune algorithm in solving the channel assignment task," in 2014 IEEE International Conference on Control System, Computing and Engineering (ICCSCE 2014), Nov 2014, pp. 153-158.
- [12] V. Rakovic and L. Gavrilovska, "Novel RAT selection mechanism based on Hopfield neural

networks,” in International Congress on Ultra Modern Telecommunications and Control Systems, Oct 2010, pp. 210-217.

[13] B. Mao, Z. M. Fadlullah, F. Tang, N. Kato, O. Akashi, T. Inoue, and K. Mizutani, “Routing or

computing? the paradigm shift towards intelligent computer network packet transmission based on deep learning,” IEEE Transactions on Computers, vol. PP, no. 99, pp. 1-1, 2017.

[14] M. Chen, W. Saad, C. Yin, and M. Debbah, “Echo state networks for proactive caching in cloud-based radio access networks with mobile users,” IEEE Trans. Wireless Commun., vol. 16, no. 6, pp. 3520 – 3535, Jun. 2017.

[15] J. Perez-Romero, O. Sallent, R. Ferrus, and R. Agusti, “A robustness analysis of learning-based coexistence mechanisms for LTE-U operation in non-stationary conditions,” in Proc. of IEEE Vehicular Technology Conference (VTC Fall), Sep. 2015

[16] M. Bennis, M. Simsek, A. Czylwik, W. Saad, W. Valentin, and M. Debbah, “When cellular meets WiFi in wireless small cell networks,” IEEE Commun. Magazine, vol. 51, no. 6, pp. 44-50, 2013.

[17] E. S. Kumar, S. M. Kusuma, and B. P. V. Kumar, “A random key distribution based artificial immune system for security in clustered wireless sensor networks,” in Electrical, Electronics and Computer Science (SCEECS), 2014 IEEE Students’ Conference on, March 2014, pp. 1-7.

[18] V. F. Taylor and D. T. Fokum, “Securing wireless sensor networks from denial-of-service attacks using artificial intelligence and the clips expert system tool,” in 2013 Proceedings of IEEE Southeast, April 2013, pp. 1-6.

[19] F. Barani, “A hybrid approach for dynamic intrusion detection in ad hoc networks using genetic algorithm and artificial immune system,” in 2014 Iranian Conference on Intelligent Systems (ICIS), Feb 2014, pp. 1-6.

[20] Y. Zou, J. Zhu, X. Wang, and L. Hanzo, “A survey on wireless security: Technical challenges, recent advances, and future trends,” Proceedings of IEEE, vol. 104, no. 9, pp. 1727-1765, Sept. 2016.

[21] D. Gkatzia, O. Lemon, and V. Rieser, “Data-to-text generation improve decision-making under uncertainty,” IEEE Computational Intelligence Magazine, vol. 12, no. 3, pp. 10-17, Aug 2017.

- [22] T. E. Bogale, X. Wang, and L. B. Le, “Adaptive channel prediction, beamforming and scheduling design for 5G V2I network,” in Proc. IEEE Veh.Technol. Conf (VTC-Fall)., Sep. 2017.

- [23] T. E. Bogale, X. Wang, and L. B. Le, “Adaptive channel prediction, beamforming and feedback design for 5G V2I network,” in IEEE (In preparation for submission), 2017.
- 593-602, March 2005.
- [24] Y. Guo, A. Korhonen, I. Silins, and U. Stenius, “A weakly-supervised approach to argumentative zoning of scientific documents,” in Proc. Of Conf. on Empir. Methods in Nat. Lang. Process., 2011, pp. 273-283.
- [25] E. Alpaydin, Introduction to Machine Learning. The MIT Press, 2014.
- [26] V. Mnih et al., “Human-level control through deep reinforcement learning,” in Nature, February 2015, pp. 529–533.
- [27] K. Arulkumaran, M. P. Deisenroth, M. Brundage, and A. A. Bharath, “Deep reinforcement learning: A brief survey,” IEEE Signal Processing Magazine, vol. 34, no. 6, pp. 26–38, Nov 2017.
- [28] Tomić, D.: Ubrzani razvoj 5G mreža. Dostupno s:
<http://www.ictbusiness.info/telekomunikacije/ubrzani-razvoj-5g-mreza> (travanj 2022.)
- [29] Kovač, L., 2017. Umjetna inteligencija danas. Diplomski rad, Filozofski fakultet u Rijeci
- [30] Kurzweil R., 2012. How to Create a Mind: The Secret of Human Thought Revealed, Viking Penguin
- [31]https://mreza.bug.hr/umjetna-inteligencija-oblikovati-ce-mreze_buducnosti/?fbclid=IwAR1sq8hC1piLBssqrMcKQmpB2himmnkmVedKxKS9LAHoqtMlh06pK05eACQ
- [32] P. Sharma, H. Liu, H. Wang, and S. Zhang, “Securing wireless communications of connected vehicles with artificial intelligence,” in 2017 IEEE International Symposium on Technologies for Homeland Security (HST), April 2017, pp. 1-7.
- [33] D. Schafhuber and G. Matz, “MMSE and adaptive prediction of time-varying channels for OFDM systems,” IEEE Tran. Wireless Commun., vol. 4, no. 2, pp. 593-602, March 2005.

PRILOZI

Popis slika

Slika 1. Optimizirani dizajn mreže s AI tehnikama	4
Slika 2. Tipična mreža sljedeće generacije koja usvaja načela AU	5
Slika 3. Usporedba analitičkog i strojnog učenja (ML)	11
Slika 4. Promet podataka uzorka apstraktne informacije	14
Slika 5. Konceptualni dijagram rada Q-učenja	17
Slika 6. Tipična struktura neuronske mreže	17
Slika 7. Arhitektura dubokog Q-učenja	18

Popis tablica

Tablica 1: Glavni problemi u radijskoj mreži s AI-om.....	10
Tablica 2: Točnost različitih metoda grupiranja	14

IZJAVA

Izjavljujem pod punom moralnom odgovornošću da sam rad izradio samostalno, isključivo znanjem stečenim na studijima Sveučilišta u Dubrovniku, služeći se navedenim izvorima podataka i uz stručno vodstvo mentora izv.prof.dr.sc.Adriane Lipovac, kojoj se još jednom srdačno zahvaljujem.

Marijo Obrovac