

PRIMENA SIONNA SOFTVERA ZA SIMULACIJE FIZIČKOG SLOJA 5G/6G MREŽA

Nenad Jevtić¹, Milica Đorđević²

¹Univerzitet u Beogradu - Saobraćajni fakultet, n.jevtic@sf.bg.ac.rs

²Rohde & Schwarz - Evaluacija mobilnih mreža, djordjevicmilica@gmail.com

Rezime: Razvoj i napredak bežičnih komunikacionih sistema zahtevaju upotrebu simulacionog softvera koji omogućava precizno modelovanje i analizu fizičkog sloja 5G (Fifth Generation) mreža. Napredne funkcionalnosti u okviru Sionna softvera pružaju robusnu platformu za simulaciju složenih dinamika veze i procenu performansi sistema. Istraživanja sprovedena u ovom radu se fokusiraju na simulaciju 5G NR (New Radio) LDPC (Low-Density Parity-Check) kodova zajedno sa MIMO (Multiple Input Multiple Output) OFDM (Orthogonal Frequency Division Multiplexing) tehnikama, otkrivajući značajna poboljšanja u performansama sistema i efikasnosti kanala. Uključivanje tehnika mašinskog učenja (ML - Machine Learning) igra ključnu ulogu u optimizaciji obrade signala i efikasnosti dekodovanja, naročito u kontekstu mreža sledeće generacije. Simulirano neuronsko demapiranje i neuronske tehnike prijema naglašavaju važnost inovativnih strategija za prevazilaženje izazova koje postavljaju nove tehnologije, uključujući one koje se očekuju u 6G (Sixth Generation) mrežama.

Ključne reči: Sionna, 5G/6G, LDPC, MIMO, OFDM, ML

1. Uvod

U istraživanjima u oblasti telekomunikacija, neophodan je fleksibilan i modularan softver za simulaciju na nivou linka kako bi se novi protokoli i algoritmi efikasno testirali, a dobijeni rezultati uporedili sa već postojećim rešenjima. Sionna softver se ističe kao jedno od rešenja koje zadovoljava ove zahteve, pružajući širok spektar mogućnosti za modelovanje komunikacionih sistema. Pre njegovog razvoja, na raspolaganju su bili *open-source* softveri ograničenih mogućnosti koji nisu mogli u potpunosti zadovoljiti sve kriterijume potrebne za simulaciju složenih mreža [1]. Sionna obezbeđuje obimnu biblioteku funkcija koja omogućava detaljno modelovanje pojedinačnih veza unutar bežičnih komunikacionih sistema, kao i interakcije između različitih čvorova i mreža [2].

U ovom radu se istražuje primena Sionna softvera za simulaciju veoma značajnih aspekata fizičkog sloja 5G (Fifth Generation) i 6G (Sixth Generation) mreža, uključujući analizu LDPC kodova (Low-Density Parity-Check) i MIMO (Multiple-Input Multiple-Output) OFDM (Orthogonal Frequency Division Multiplexing) tehnike. Pored

toga, istražuje se integracija metoda mašinskog učenja i vrši evaluacija primene neuronskih mreža u mobilnim sistemima. Kroz simulaciju tehnika neuronorskog demapiranja se naglašava sposobnost sistema da iterativno optimizuje konstelacioni dijagram, poboljšavajući detekciju simbola i minimizujući greške u kanalima sa šumom. Takođe, predstavljena je struktura neuronorskog prijemnika, pri čemu je sprovedena evaluacija sa tradicionalnim modelima.

Rad je organizovan na sledeći način. Detaljan opis Sionna softvera predstavljen je u drugom poglavlju. Treće poglavlje prikazuje simulacione analize odabranih tehnika u komunikacionim sistemima, dok je četvrto poglavlje fokusirano na istraživanje i evaluaciju neuronskih tehnika u mobilnim sistemima. Zaključna razmatranja koja proizilaze iz istraživanja i sprovedenih simulacija su data u petom poglavlju.

2. Pregled funkcionalnosti Sionna softvera

Sionna softver nudi fleksibilne mogućnosti modelovanja i analize za bežične komunikacione sisteme. Biblioteka sadrži niz modularnih komponenti koje služe kao osnovni gradivni blokovi za kreiranje modela naprednih komunikacionih sistema prilagođenih specifičnim potrebama. Integracija Python-a, Keras API-ja (*Application Programming Interface*) i TensorFlow-a, obezbeđuje efikasnu platformu za razvoj, obučavanje i evaluaciju ML (*Machine Learning*) i DL (*Deep Learning*) modela učenja. Kroz sveobuhvatan API, Sionna smanjuje složenost sistema, omogućava brzo modelovanje "od kraja do kraja" i nudi prilagodljive opcije za različite istraživačke oblasti.

Sionna obezbeđuje i modele za simulaciju bežičnih kanala koji uzimaju u obzir feding, gubitak snage signala i interferenciju, omogućavajući korisnicima da simuliraju realne bežične okoline. Obuhvaćeni su osnovni modeli feding kanala uključujući *Rayleigh* i *Rician* modele, dok se uticaj gubitka snage signala može modelovati kao gubitak u slobodnom prostoru ili korišćenjem *Two-ray ground* modela. Efekti modela *shadowing-a* se mogu simulirati, omogućavajući razumevanje složenih interakcija između bežičnih signala i njihove okoline. Osim osnovnih, postoji i veći broj modela kanala u skladu sa tehničkim izveštajima 3GPP (3rd Generation Partnership Project), pogodnih za modelovanje 5G sistema. Modularna arhitektura omogućava integraciju različitih komponenti, poput različitih tipova antena i konfiguracija, što je ključno za implementaciju MIMO i OFDM tehnika. U oblasti obrade signala, Sionna nudi robustan skup alata za simulaciju, podržavajući širok spektar šema modulacije, kao što su QPSK (*Quadrature Phase Shift Keying*) i QAM (*Quadrature Amplitude Modulation*), kao i FEC (*Forward Error Correction*) tehnike, uključujući konvolucione kodove, turbo kodove i LDPC kodove. Performanse tehnika ekvalizacije, kao što su linearna i ekvalizacija sa povratnim odlučivanjem, mogu se detaljno ispitati kako bi se optimizovali bežični komunikacioni sistemi. Evaluacija ključnih performansi, uključujući propusni opseg, latenciju i verovatnoću greške, omogućava sveobuhvatnu analizu efikasnosti sistema.

Jedna od ključnih prednosti Sionna biblioteke je njena skalabilnost i visoke performanse, koje se postižu putem paralelne obrade signala i ubrzanja procesiranja korišćenjem GPU (*Graphics Processing Unit*), omogućavajući simulaciju velikih bežičnih komunikacionih sistema sa izuzetnom brzinom i preciznošću. Pored toga, mogućnosti distribuirane simulacije omogućavaju modelovanje složenih sistema koji obuhvataju više čvorova i mreža. Modularna arhitektura podržava prilagodljivost za širok

spektar bežičnih komunikacionih sistema i scenarija, uključujući 5G mrežu, milimetarske talase (*mmWave*), VANET (*Vehicular Ad-hoc Network*) mreže, IoT (*Internet of Things*) i satelitske komunikacione sisteme. Sposobnost biblioteke da integriše nove tehnologije i podrži složene simulacije čini je idealnim softverom za istraživanje novih inovacija u 6G tehnologiji.

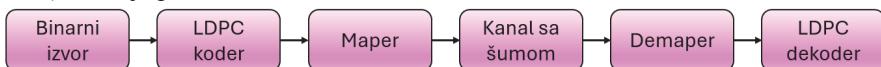
3. Simulaciona analiza primene LDPC i MIMO OFDM u komunikacionim sistemima

U prenosu digitalnih podataka, cilj je osigurati da svi podaci koji su poslati kroz komunikacioni kanal budu primljeni bez grešaka. Merenjem broja netačnih bitova omogućava se evaluacija performansi sistema i identifikacija gde je potrebno unapređenje. Ova merenja mogu biti izražena kroz metrike kao što su BER (*Bit Error Rate*) ili BLER (*Block Error Rate*), koje pružaju kvantitativne informacije o tačnosti prenosa podataka i pouzdanosti digitalne komunikacije.

U ovom poglavlju predstavljeni su rezultati simulacija sa fokusom na 5G NR LDPC kodove i MIMO OFDM tehniku. Korišćenje LDPC kodova značajno poboljšava mogućnosti korekcije grešaka, omogućavajući sistemu da se efikasno suprotstavi efektima šuma i interferencije u prenosu podataka [3]. Kroz integraciju MIMO sistema i OFDM tehnike, značajno se unapređuje način rešavanja izazova vezanih za iskorišćenje propusnog opsega i prevenciju *multi-path* feedinga, što rezultira obezbeđivanju većeg integriteta podataka [4]. Kod i rezultati izvršenih simulacija dostupni su na Google Colab-u [5].

3.1. Simulaciona analiza LDPC kodova

Sionna softver sadrži unapred definisane funkcionalnosti namenjene simulaciji složenih aspekata 5G mreža, uključujući i modele za zaštitno kodovanje (LDPC koder i dekoder), kako je prikazano na slici 1.

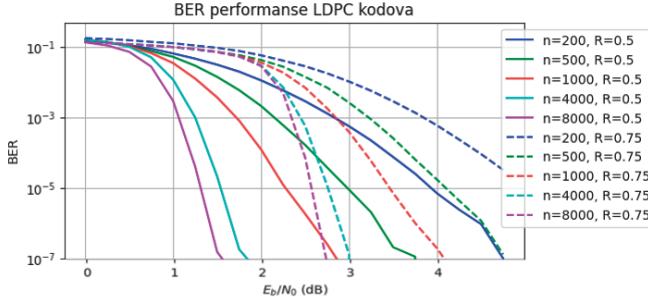


Slika 1. Komunikacioni sistem sa zaštitnim kodovanjem

Nakon generisanja nasumičnog niza bitova pomoću binarnog izvora, vrši se zaštitno kodovanje nad ulaznim bitovima. Kanalski (zaštitni) kodovi se dodaju u komunikacioni sistem kako bi primopredajnik bio robustniji, odnosno kako bi mogao da otklanja greške u prenosu. Rezultat je kodovana poruka koja se dalje prevodi u niz simbola i procesira kroz kanal sa šumom. Na izlazu kanala poruka se iz niza simbola prevodi nazad u niz bita i dekoduje, potom se na kraju vrši poređenje ulazne i izlazne sekvence bita kako bi se videli efekti primene zaštitnog kodovanja, odnosno definisale BER krive.

Simulacija je fokusirana na analizu performansi LDPC kodova, koji se koriste u 5G NR sistemima zbog svojih izuzetnih sposobnosti ispravljanja grešaka. Kao deo ovog istraživanja, sprovedena je prilagođena simulacija kako bi se procenilo kako različiti faktori utiču na performanse. Vrednost kodnog količnika i dužina kodne reči variraju, dok ostali parametri, kao što su dekoder i kanal, ostaju konstantni. Simulacija koristi seriju LDPC kodova koji se testiraju, pri čemu se dužina kodne reči postepeno povećava (200,

500, 1000, 4000, 8000). Za svaku dužinu kodne reči, broj informacionih bitova se izračunava na osnovu kodnog količnika $R = \frac{1}{2}$ i $R = \frac{3}{4}$. Simulacija prenosa podataka kroz kanal je sprovedena za svaki par koder/dekoder, a za svaku dužinu kodne reči, kodnog količnika i vrednost SNR (*Signal-to-Noise Ratio*). Na osnovu rezultata simulacije može se zaključiti kako performanse LDPC kodova zavise od kodnog količnika, kao i od dužine kodne reči.



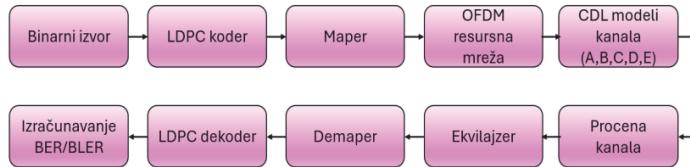
Slika 2. BER performanse LDPC kodova

Rezultati simulacije prikazani su na slici 2, pri čemu su BER krive za kodni količnik $\frac{1}{2}$ predstavljene neisprekidanim linijama, dok su za kodni količnik $\frac{3}{4}$ prikazane isprekidanim linijama. Upoređujući ove BER krive, dolazi se do zaključka da kodni količnik igra ključnu ulogu u definisanju balansa između efikasnosti prenosa podataka i otpornosti na greške. Podešavanjem na manju vrednost ($R = \frac{1}{2}$) povećava se broj bitova posvećenih korekciji grešaka, što poboljšava otpornost na šum i interferencije, što se jasno vidi na BER krivama prilikom poređenja oba kodna količnika. Međutim, time se smanjuje protok, jer se manji deo prenetih podataka koristi za korisne informacije. S druge strane, veća vrednost kodnog količnika ($R = \frac{3}{4}$), omogućava veći kapacitet za korisne podatke, ali smanjuje otpornost na greške. Takođe, dobijeni rezultati potvrđuju da duže kodne reči imaju veći kapacitet za prenos informacija i veću otpornost na greške, što dovodi do nižeg BER-a. Međutim, duže kodne reči zahtevaju više vremena za obradu, što povećava vreme dekodovanja i kašnjenje u 5G sistemima. Ovo je jasno uočeno u simulacijama, gde se vreme izvršenja simulacije povećava sa dužinom kodne reči. Stoga, pri odabiru optimalne kombinacije kodnog količnika i dužine kodne reči, neophodno je pažljivo proceniti ravnotežu između vremena obrade, otpornosti na greške i efikasnosti prenosa, u zavisnosti od specifičnih zahteva primene.

3.2. Simulaciona analiza MIMO OFDM tehnike

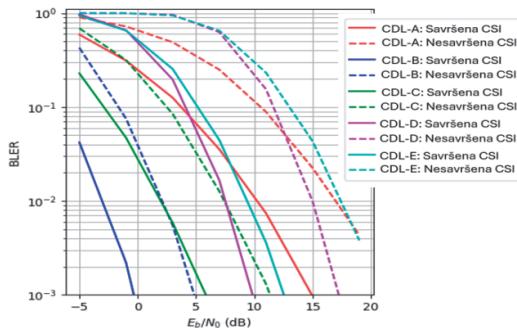
Blok dijagram modela sistema koji se simulira prikazan je na slici 3. Model predstavlja osnovnu strukturu sistema komunikacije u 5G mreži koja obuhvata više različitih modula sa ciljem da se ostvari što vernija i efikasnija simulaciona analiza. Korišćeni su slojevi za generisanje nasumičnih podataka, modulaciju, kodovanje i dekodovanje signala, OFDM resursne mreže, kao i predajnici i prijemnici sa više antena. U analizi je korišćen 3GPP TR 38.901 CDL (*Clustered Delay Line*) kanal, koji uključuje pet različitih tipova modela (A, B, C, D, E). Razvijeni su kako bi omogućili simulaciju različitih scenarija u okviru 5G mreža, od urbanih do ruralnih sredina, uključujući i izazovna okruženja sa brojnim refleksijama i rasipanjem signala. CDL-A model simulira relativno jednostavne scenarije višestrukih putanja sa malim brojem refleksija i pogodan

je za ruralna ili jednostavna urbana okruženja gde nema mnogo refleksija i disperzije signala. CDL-B model simulira složenje scenarije sa većim brojem višestrukih putanja i refleksija i pogodan je za prigradske oblasti ili okruženja sa srednjim brojem prepreka (npr. kuće, niske zgrade). CDL-C je još složeniji model koji se koristi za urbana okruženja sa velikim brojem zgrada, prepreka i objekata koji mogu reflektovati signal. CDL-D model simulira veoma složene scenarije, uključujući guste gradske sredine sa velikim brojem prepreka i refleksija i idealan je za veoma gусте urbane oblasti, gde je signal izložen velikom broju višestrukih refleksija (npr. centri gradova, poslovne četvrti). CDL-E je najkompleksniji model i koristi se za simulaciju složenih scenarija, kao što su unutrašnje prostorije (*indoor*) sa mnogo refleksija i disperzija signala (npr. tržni centri, stanice, poslovni prostori). Parametri za svaki model nalaze se u tabelama specifikacije 3GPP TR 38.901 [6]. Za procenu karakteristika kanala koristi se metoda LS (*Least Squares*), uz primenu interpolacije najbližeg suseda (*Nearest-Neighbor*) radi poboljšanja tačnosti procene. Za optimalno prilagodavanje parametara sistema koristi se savršena CSI (*Channel State Information*). Takođe, LMMSE (*Linear Minimum Mean Square Error*) tehnika se koristi za ekvalizaciju MIMO sistema.



Slika 3. Blok dijagram simuliranog modela sistema

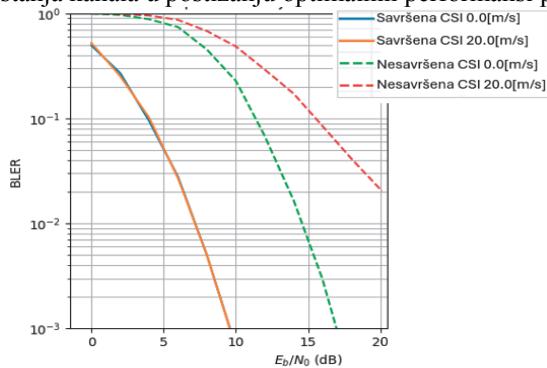
U okviru simulacije analizira se *uplink* prenos između korisničkog terminala sa 4 antene i bazne stанице sa 8 antena, korišćenjem MIMO OFDM tehnike. Sistem je konfigurisan tako da broj strimova po predajniku odgovara broju antena na korisničkom terminalu, što omogućava efikasniji prenos podataka jer broj strimova direktno prati raspoložive antene na terminalu. Rezultati simulacije su prikazani na slici 4, gde su neispredanim BLER krivama označeni modeli koji koriste savršeno znanje o stanju kanala, dok ispredane BLER krive predstavljaju modele koji koriste procenu kanala i imaju nepotpuno znanje o stanju kanala. Upoređujući ove BLER krive, dolazi se do zaključka da su performanse sistema bolje kada se koristi savršeno znanje o stanju kanala, što je i očekivan rezultat. Međutim, važno je napomenuti da savršeno znanje o stanju kanala nije realno u praktičnim primenama bežičnih komunikacionih sistema. U većini slučajeva, kanal se procenjuje na osnovu dostupnih podataka i parametara, što može rezultirati nepotpunim znanjem ili procenom kanala.



Slika 4. Simulacija MIMO OFDM tehnike

Rezultati jasno ukazuju da modeli CDL-B i CDL-C pružaju bolje performanse u urbanim makro okruženjima, čak i pri nižim vrednostima E_b/N_0 , što je evidentno u oba slučaja, sa savršenom i nesavršenom CSI. Ova stabilnost ih čini pogodnim za simulacije u scenarijima sa velikim brojem refleksija i višestrukim putanjama signala. CDL-D model, koji se koristi za kanale sa velikim brojem višestrukih putanja je osetljiviji pri nesavršenim informacijama o kanalu. S druge strane, modeli CDL-A i CDL-E pokazuju veću osetljivost na varijacije u kanalima, posebno u uslovima bez savršene CSI informacije. CDL-E model, iako pruža bolje rezultate sa savršenim CSI-jem, beleži značajno više BLER vrednosti pri nesavršenom znanju o stanju kanala.

Uspostavljanje kvalitetne i pouzdane radio veze u sistemima mobilnih komunikacija predstavlja veliki izazov zato što ovaj kanal nije podložan samo šumu, interferenciji i drugim smetnjama, već se karakteristike kanala menjaju tokom vremena na nepredvidiv način usled kretanja mobilnih korisnika i okolnih objekata zbog čega dolazi do stalnih promena uslova okruženja. Izvršena simulacija jasno prikazuje uticaj mobilnosti korisničkog terminala na performanse u CDL-D kanalu, pri različitim brzinama korisničkog terminala (0 m/s i 20 m/s). Rezultati prikazani na slici 5 ističu značaj poznavanja stanja kanala u postizanju optimalnih performansi prenosa.



Slika 5. Uticaj mobilnosti korisničkog terminala u CDL-D kanalu

Kada je CSI savršena, mobilnost korisničkog terminala ima relativno mali uticaj na performanse, što se jasno vidi sa slike 5 gde puna plava i narandžasta linija pokazuju veoma slične vrednosti, jer precizna informacija o kanalu omogućava efikasnu korekciju grešaka i upravljanje signalom čak i u pokretnom okruženju. Međutim, kada se vrši realna procena kanala, dolazi do značajne degradacije performansi. Zelena isprekidana linija, koja prikazuje scenario sa statičnim korisničkim terminalom, pokazuje da i bez mobilnosti, greške u proceni kanala značajno otežavaju ispravljanje grešaka u prenosu podataka. Crvena isprekidana linija prikazuje dodatno pogoršanje performansi zbog mobilnosti, zato što kretanje dodatno otežava procenu kanala i stabilnost signala. Mobilnost unosi veće varijacije u kanal, čineći ovaj scenario izuzetno zahtevnim za održavanje kvalitetnog prenosa podataka i zahtevajući znatno veće E_b/N_0 vrednosti za postizanje željenog BLER nivoa.

4. Istraživanje i evaluacija neuronskih tehnika u mobilnim sistemima

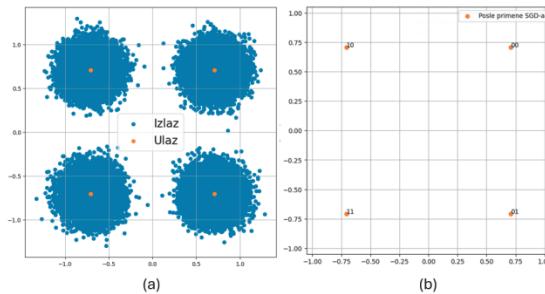
Bežične i mobilne aplikacije doživele su značajan rast, što direktno utiče na povećanje zahteva u okviru mobilnih sistema pete generacije i budućih generacija, poput

6G sistema. S obzirom na sve veću potrebu za efikasnom obradom i dekodovanjem signala, neophodno je pronaći rešenja koja mogu odgovoriti na nove zahteve i omogućiti stabilan prenos podataka. Kako bi se ovi izazovi prevazišli, ML metode se sve više integrišu u komunikacione sisteme, omogućavajući adaptivnija i efikasnija rešenja [7].

U ovom poglavlju predstavljeni su rezultati istraživanja i evaluacije neuronskih tehnika u mobilnim sistemima kroz eksperimente sa neuronskim demapiranjem, koji ukazuju na značajna poboljšanja u optimizaciji prijemnika. Takođe, kroz simulacije i treniranje neuronskog prijemnika sa velikim brojem iteracija, omogućava se postizanje performansi koje su približno jednake savršenom poznavanju stanja kanala, što predstavlja veliki potencijal za buduće 6G mreže.

4.1. Simulaciona analiza neuronskog demapiranja

Simulacija prikazuje prenos simbola kroz kanal sa AWGN šumom, modulisanih pomoću QAM modulacije, ilustrujući kako šum utiče na kvalitet i pouzdanost prenosa signala. Tehnika optimizacije konstelacionog dijagrama pomoću SGD algoritma (*Stochastic Gradient Descent*) omogućava precizniju rekonstrukciju simbola i poboljšanje performansi sistema. Na slici 6a, plave tačke predstavljaju primljene simbole, koji su raspršeni i pokazuju značajna odstupanja od idealnih pozicija konstelacije (narandžaste tačke) usled prisustva šuma u kanalu, čime se dodatno naglašava izazov održavanja preciznosti simbola u takvim uslovima. Nasuprot tome, slika 6b prikazuje optimizovani konstelacioni dijagram nakon primene SGD algoritma. Svaka narandžasta tačka predstavlja simbol u 4-QAM konstelaciji i nosi odgovarajuću sekvencu bitova, što ukazuje na značajno poboljšanje procesa prevođenja niza simbola nazad u niz bitova. Sistem prilagođava tačke konstelacije i podešava granice odlučivanja kako bi smanjio BER, što rezultira značajnim poboljšanjem preciznosti klasifikacije primljenih simbola. Neuronski demaper optimizuje proces dekodovanja tako što iterativno poboljšava tačke konstelacije, što ukazuje na potencijal mašinskog učenja za unapređenje komunikacionih sistema.



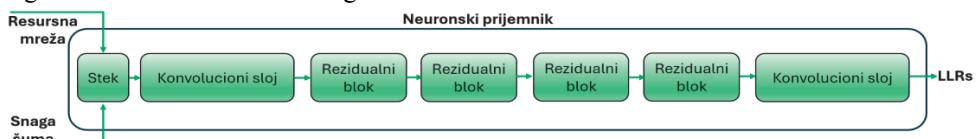
Slika 6. Konstelacioni dijagram na predaji i prijemu bez SGD (a) i sa SGD (b)

4.2. Simulaciona analiza neuronskog prijemnika

Tradicionalni prijemnici koriste matematičke metode za obradu signala i dekodovanje, što se pokazalo efikasnim u prethodnim generacijama mobilnih mreža. Međutim, kako složenost i kompleksnost mobilnih mreža raste, javlja se sve veća potreba za adaptivnjim tehnikama koje mogu da odgovore na dinamične i brzo promenljive uslove kanala. U ovakvim okruženjima, tradicionalni prijemnici sve češće pokazuju svoja

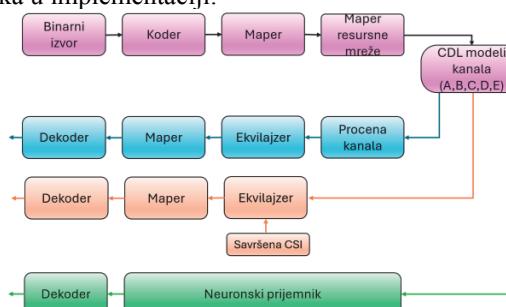
ograničenja, jer kompleksni uslovi, poput višestrukih refleksija, šuma i brzih varijacija kanala, zahtevaju naprednije metode koje efikasno održavaju stabilnost i visok nivo performansi sistema. Ovi faktori su od suštinskog značaja za postizanje pouzdanog prenosa podataka, a rešenja se sve više pronalaze u savremenim tehnikama koje koriste veštačku inteligenciju i neuronske mreže. Neuronski prijemnici, bazirani na DL (*Deep Learning*) metodama, pojavljuju se kao obećavajuće rešenje u modernim bežičnim komunikacionim sistemima jer nude sposobnost prilagođavanja na dinamične kanale i složene šeme modulacije, čime se omogućava efikasniji prenos podataka i smanjenje grešaka. Koristeći duboke neuronske mreže, tačnije konvolucione slojeve, prijemnici mogu automatski da uče i prilagođavaju procese dekodovanja signala na osnovu podataka primljenih sa kanala.

Neuronski prijemnik, čija je šema prikazana na slici 7, funkcioniše tako što obrađuje ulazne podatke kroz niz slojeva kako bi pružio precizne informacije o simbolima koji su poslati preko kanala. Ulaz u neuronski prijemnik čine resursna mreža i podaci o snazi šuma. Stek služi za pripremu i organizovanje strukture podataka koju prijemnik dalje obrađuje, što često podrazumeva raspoređivanje podataka na način koji omogućava efikasniju obradu u sledećim slojevima modela. Konvolucioni slojevi su ključni deo dubokih neuronskih mreža, vrše filtriranje primljenih podataka kako bi izvukli relevantne karakteristike iz simbola. Rezidualni blokovi omogućavaju zadržavanje važnih informacija kroz višeslojne mreže i pomažu u prevazilaženju problema nestajućih gradijenata tokom treniranja. Na ovaj način, neuronski prijemnik se efikasnije prilagođava promenama u ulaznim podacima i prisustvu šuma. LLR (*Log-Likelihood Ratios*) vrednosti na izlazu prijemnika predstavljaju logaritamski odnos verovatnoća za dekodovanje bita, pri čemu veća vrednost LLR-a ukazuje na veću sigurnost u tačnost dekodovanog bita.



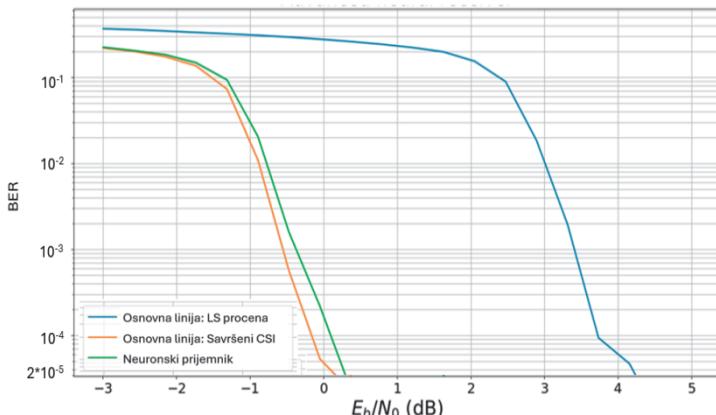
Slika 7. Šema neuronskog prijemnika

Evaluacija neuronskog prijemnika sprovedena je kroz simulacije, gde su performanse treniranog modela upoređene sa sistemima koji koriste LS procenu kanala i savršeno poznavanje stanja kanala. Struktura sva tri sistema prikazana je na slici 8, što omogućava pregled razlika u implementaciji.



Slika 8. Evaluacija neuronskog prijemnika sa tradicionalnim modelima

Rezultati simulacija, koji su prikazani na slici 9, pružaju uvid koliko se trenirani neuronski prijemnik može približiti idealnim uslovima koji se postižu uz savršenu CSI, i koliko može da nadmaši tradicionalne pristupe, posebno kada su prisutne varijacije u kanalu ili složeniji uslovi propagacije signala. U odnosu na tradicionalne sisteme koji zahtevaju detaljno modelovanje kanala, neuronski prijemnik može da se trenira na različitim scenarijima i dinamički prilagođava promenljivim uslovima na osnovu ulaznih podataka. Ovo je od suštinskog značaja u uslovima kada su prisutni različiti šumovi, interferencije i smetnje, jer neuronski prijemnik može naučiti kako da optimizuje dekodovanje signala bez potrebe za prethodnim znanjem o karakteristikama kanala. Time se obezbeđuju značajne prednosti u promenljivim okruženjima, kao što su mobilni sistemi pete i šeste generacije, gde se signali često menjaju zbog fizičkih prepreka, refleksija ili kretanja korisničkih terminala.



Slika 9. Evaluacija neuronskog prijemnika

5. Zaključak

Raznovrsnost Sionna softvera obuhvata mnogo više od primera predstavljenih u ovom istraživanju. Simulacije 5G NR LDPC kodova, MIMO OFDM-a, kao i neuronske tehnike demapiranja i prijemnika, predstavljaju samo deo potencijala u istraživanju bežičnih komunikacija. Kao *open-source* platforma, Sionna se kontinuirano unapređuje zahvaljujući doprinosima globalne zajednice, čime se obezbeđuje prilagodljivost novim tehnologijama. Skalabilnost čini ovu biblioteku idealnom platformom za širok spektar istraživačkih inicijativa, od usavršavanja postojećih tehnika do razvoja potpuno novih paradigmi u bežičnim komunikacijama. Kako rastu zahtevi za performansama i fleksibilnošću mreža, zahvaljujući mogućnostima integracije sistema zasnovanih na mašinskom učenju, Sionna pruža veliki potencijal za istraživanje i razvoj dizajna mobilnih sistema šeste generacije.

Budući rad može uključivati istraživanje složenih propagacionih okruženja, multi-hop komunikaciju ili strategije naprednog upravljanja interferencijama. Pored toga, integracija sofisticiranih modela mašinskog učenja mogla bi omogućiti prilagodljivost i donošenje odluka u realnom vremenu, otvarajući put ka inteligentnim, autonomnim mrežama.

Literatura

- [1] Sionna [Online]. Available: <https://nvlabs.github.io/sionna/index.html>
- [2] J. Hoydis, S. Cammerer, F. A. Aoudia, A. Vem, N. Binder, G. Marcus, and A. Keller, "Sionna: An open-source library for next-generation physical layer research," 2022, arXiv:2203.11854. [Online]. Available: <https://arxiv.org/abs/2203.11854>
- [3] J. H. Bae, A. Abotabl, H. P. Lin, K. B. Song, J. Lee, "An Overview of channel coding for 5G NR cellular communications", *Industrial Technology Advances*, vol.8, pp. 1-14, 2019. DOI: 10.1017/ATSI.2019.10
- [4] . Patil, M. R. Patil, S. Itraj, U. L. Bomble, "A Review on MIMO OFDM Technology Basics and More", in *Proc of Intern. Conf. on Current Trends in Comp., Electrical, Electronics and Communication*, Mysore, India, pp.119-122, 2017.
- [5] M. Đorđević, "Primena Sionna softvera za simulacije fizičkog sloja 5G/6G mreža" [Online].Available:
<https://colab.research.google.com/drive/1BwttsrLlgaGXOvcZEVu6dZGgMqgOCK7qi#scrollTo=bEfbXDy9g3Dx>
- [6] 3GPP Specification TR 38.901, Version 17.1.0 [Online]. Available:
<https://portal.3gpp.org/desktopmodules/Specifications/SpecificationDetails.aspx?specificationId=3173>
- [7] Y. Shi, L. Lian, Y. Shi, Z. Wang, Y. Zhou, L. Fu, "Machine Learning for Large-Scale Optimization in 6G Wireless Networks", *IEEE Comm. Surveys & Tutorials*, vol. 25, pp. 2088 - 2132, 2023.

Abstract: *The evolution and progress of wireless communication systems necessitate the use of simulation software capable of accurately modeling and analyzing the physical layer of 5G (Fifth Generation) networks. Advanced functionalities within the Sionna software provide a robust platform for simulating complex link dynamics and assessing system performance. This study centers on the simulation of 5G NR (New Radio) LDPC (Low-Density Parity-Check) codes alongside MIMO (Multiple Input Multiple Output) OFDM (Orthogonal Frequency Division Multiplexing) techniques, revealing notable enhancements in both system performance and channel efficiency. The incorporation of ML (Machine Learning) techniques plays a critical role in optimizing signal processing and decoding efficiency, particularly in the context of next-generation networks. Simulated neural demapping and neural receiver methods underscore the importance of innovative strategies to overcome challenges posed by emerging technologies, including those anticipated in 6G (Sixth Generation) networks.*

Keywords: *Sionna, 5G/6G, LDPC, MIMO, OFDM, ML*

APPLICATION OF SIONNA SOFTWARE FOR PHYSICAL LAYER SIMULATIONS OF 5G/6G NETWORKS

Nenad Jevtić, Milica Đorđević