

Modelovanje *Power Delay Profile* radio kanala primenom neuralnih mreža

Marko Burdžić, Nataša Nešković, Aleksandar Nešković

Elektrotehnički fakultet, Univerzitet u Beogradu

Beograd, Srbija

marko.burdzic@etf.rs, natasha@etf.rs, neshko@etf.rs

Sažetak — Modelovanje radio kanala predstavlja osnovu za projektovanje bežičnih komunikacionih sistema. Informacije o stanju u radio kanalu mogu se iskoristiti za tehnike prostornog multipleksiranja i *beamforming-a*, sa krajnjim ciljem povećanja kapaciteta sistema. Takođe, za poboljšanje performansi bežičnih komunikacionih sistema, važna je precizna procena *multipath* komponenti. Za tu svrhu od velikog značaja je tzv. profil zakasnelih snaga (*Power Delay Profile* – PDP). Cilj ovog rada je formiranje optimalnog modela za estimaciju PDP profila primenom *Multilayer perceptron* (MLP) neuralne mreže uzimajući u obzir različitu širinu radio kanala i frekvencijsku rezoluciju. Zaključuje se da predložena arhitektura neuralne mreže omogućava kvalitetnu estimaciju.

Ključne reči - Radio kanal; *Power delay profile*; *Multilayer perceptron*; *Artificial Neural Networks*.

I. UVOD

Bežične komunikacione sisteme karakteriše revolucionarni napredak u poslednjih nekoliko godina. Broj bežičnih korisnika, kao i njihovi zahtevi za većim protocima kontinualno rastu [1]. Nove tehnologije pete generacije (5G) i nadolazeća šesta generacija (6G) omogućavaju veoma atraktivne industrijske primene poput autonomnih vozila, pametnih fabrika, telemedicine... Rezultat je povećanje složenosti dizajna bežičnih sistema, kao i znatno veća očekivanja kada su u pitanju kvalitet mreže, pouzdanost, raspoloživost i fleksibilnost. S obzirom na veliku složenost dizajniranja ovakvih sistema, tradicionalne metode modelovanja kanala više ne mogu zadovoljiti potrebe novih servisa [2]. Modelovanje radio kanala predstavlja osnovu za projektovanje bežičnih komunikacionih sistema. U osnovi modelovanja radio kanala je analiza propagacionih mehanizama i otkrivanje odnosa između propagacionog okruženja i karakteristika radio kanala [3]. Cilj modelovanja radio kanala je da na adekvatan način obezbedi informacije o stanju u radio kanalu i uključi ih u različite tehnike, kao što su prostorno multipleksiranje i *beamforming*, koje će doprineti povećanju kapaciteta sistema. Pored toga, tačna procena *multipath* komponenti ima važnu ulogu u povećanju performansi bežičnih komunikacionih sistema koje su neophodne za pouzdano funkcionisanje budućih servisa [2]. Za tu svrhu od značaja je profil zakasnelih snaga (*Power Delay Profile* - PDP) koji se može koristiti za procenu prosečne raspodele snaga u *multipath* kanalu, mereno od

komponente signala koja prva stiže u prijemnik do poslednje komponente signala čiji je nivo snage iznad određenog praga [4].

Kako tradicionalni statistički i empirijski modeli ne mogu istovremeno zadovoljiti i tačnost i računarsku efikasnost, kao kompromisno rešenje za potrebe modelovanja radio kanala, koje bi moglo ispuniti oba zahteva, mogu se koristiti veštačke neuralne mreže [5]. Modeli veštačke inteligencije se ističu u rešavanju problema koji uključuju više dimenzija i složenu dinamiku, pri čemu imaju potencijal optimizacije podataka u skoro realnom vremenu, kao i mogućnost estimacije svojstava radio kanala za nepoznate scenarije, nove frekvencijske opsege i različite vremenske trenutke [2].

Cilj ovog rada je formiranje optimalnog modela baziranog na veštačkim neuralnim mrežama koji estimira PDP profil uzimajući u obzir različitu širinu radio kanala i frekvencijsku rezoluciju. Za estimaciju PDP profila korišćena je *feedforward Multilayer perceptron* (MLP) neuralna mreža. I pored toga što se radi o fundamentalnoj *feedforward* neuralnoj mreži, čak i MLP sa tri sloja može predstavljati dobar izbor za opisivanje ponašanja radio kanala sa željenom tačnošću [5]. Iako se za rešavanje ovog problema mogu koristiti i znatno složenije arhitekture neuralnih mreža, poput *Long Short-Term Memory* (LSTM) mreže [3], [5], osnovna ideja za korišćenje MLP neuralne mreže je da se pokaže da i sa jednostavnom arhitekturom mogu da se postignu zadovoljavajući rezultati. U radu su PDP profili koji su generisani "obučenom" neuralnom mrežom poređeni sa vrednostima određenim na osnovu merenja impulsnog odziva radio kanala kako bi se procenila tačnost istreniranog modela. Na raspolaganju je bio veliki skup mernih podataka impulsnog odziva za različite širine radio kanala i frekvencijsku rezoluciju [6].


Rad je koncipiran na sledeći način: U II poglavlju dat je opis mernih rezultata koji su korišćeni za treniranje neuralne mreže. Detaljan prikaz predložene arhitekture MLP neuralne mreže dat je u poglavlju III. U IV poglavlju je objašnjen postupak treniranja neuralne mreže. Rezultati predikcije PDP profila prikazani su u V poglavlju. U poslednjem, VI poglavlju, izvedeni su zaključci.

II. PODACI KORIŠĆENI ZA OBUKU

Za potrebe ovog rada, korišćeni su rezultati merenja iz rada [6]. Na raspolaganju su bili rezultati merenja za širine radio kanala od 10 MHz, 20 MHz, 25 MHz, 30 MHz, 50 MHz, 100 MHz i 200 MHz sa frekvencijskim rezolucijama od 10 kHz i 100 kHz. Za svaku definisanu širinu radio kanala i svaku rezoluciju, merenja su ponovljena sto puta kako bi se generisala relevantna statistička slika o parametrima kanala. Za svako pojedinačno merenje generisana je 2001 tačka impulsnog odziva. Detaljniji opis merenja, kao i obrade rezultata merenja, može se naći u radu [6]. Na Sl. 1 prikazan je primer impulsnog odziva za širinu kanala $B = 100$ MHz i frekvencijsku rezoluciju $\Delta f = 10$ kHz za svih sto merenja.

III. ARHITEKTURA NEURALNE MREŽE

Nakon sveobuhvatne analize koja je podrazumevala simulaciju različitih arhitektura neuralne mreže, za potrebe predikcije PDP profila izabrana je *Multilayer perceptron* (MLP) *feedforward* neuralna mreža. Broj neurona ulaznog sloja odgovara broju obeležja (*features*) ulaznih podataka. Kako postoji samo jedno obeležje, a to je kašnjenje, broj neurona u ulaznom sloju je 1. Neuralna mreža ima deset skrivenih *Dense* slojeva, od kojih prva četiri skrivena sloja imaju po 512 neurona, naredna tri sloja po 256 neurona, dok preostala tri skrivena sloja imaju po 128 neurona (Sl. 2). *Dense* sloj je jedan od najčešće korišćenih slojeva i podrazumeva da su neuroni iz prethodnog sloja povezani sa svim neuronima iz narednog sloja. Poslednji sloj ima samo jedan neuron, budući da mreža treba da prediktuje samo jednu vrednost – snagu izraženu u dBm. Da bi se izbegao problem nestajućeg gradijenta, koji se javlja u neuralnim mrežama, u skrivenim slojevima korišćena je ReLU (*Rectified Linear Unit*) aktivaciona funkcija. Sama arhitektura je kreirana na taj način da se izbegne pretreniranost. Tehnike u borbi protiv pretreniranosti se nazivaju regularizacija [7]. Najjednostavniji način da se spreči pretreniranost je da se smanji dimenzija



Slika 1 Impulsni odzivi za svih sto merenja za širinu kanala $B = 100$ MHz i frekvencijsku rezoluciju $\Delta f = 10$ kHz [6]

neuralne mreže, odnosno da se smanji broj slojeva i broj neurona u svakom od slojeva. Na taj način, smanjuje se broj parametara koje neuralna mreža treba da nauči. U dubokom učenju, broj parametara za učenje (težinskih koeficijentata i *bias-a*) odnosi se na kapacitet modela. Sa druge strane, model treba da ima dovoljno parametara da ne bi bio neobučen (*underfitting*). Indikator da je mreža neutrenirana je velika greška na trening skupu podataka [8], [2].

Za kreiranje opisane arhitekture mreže korišćen je programski jezik *Python* i biblioteke otvorenog koda *Tensorflow* i *Keras*.

IV. TRENIRANJE MODELA

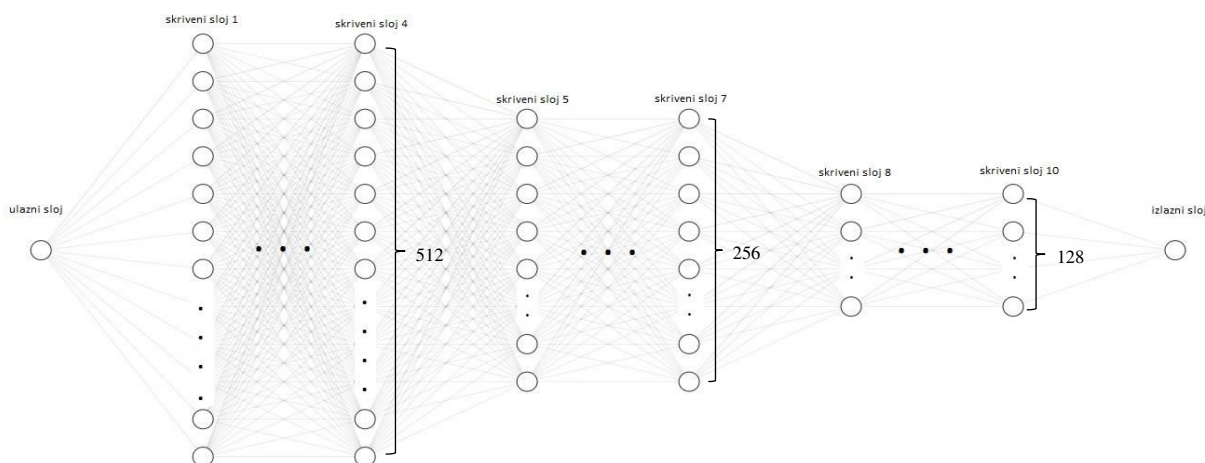
Predikcija PDP profila predstavlja regresioni problem, odnosno zadatak je da se odredi kontinualna veličina snage izražene u dBm u funkciji od kašnjenja. S obzirom na to da za svako kašnjenje postoji odgovarajući nivo snage na osnovu kojeg mreža uči, reč je o nadgledanom učenju (*supervised learning*).

Ulaz u neuralnu mrežu je kašnjenje izraženo u ns, dok je izlaz snaga signala izražena u dBm. Jedan impulsni odziv je definisan u 2001 tački [6]. Kako je za jednu kombinaciju širine kanala i frekvencijske rezolucije ukupno izvršeno sto merenja, to znači da postoji ukupno 200100 izlaznih podataka. Kako bi za svaku ulaznu vrednost postojala odgovarajuća izlazna vrednost, svaki trenutak kašnjenja će biti ponovljen sto puta. Na taj način će za svaki ulazni podatak postojati odgovarajući izlazni podatak. Dakle, ukupan skup podataka čini 200100 parova (ulaz, izlaz) koji su normalizovani prema formuli (1), a zatim pretvoreni u tenzore zbog kompatibilnosti sa slojevima neuralne mreže.

$$data_{norm} = \frac{(data - min_data)}{(max_data - min_data)} \quad (1)$$

U formuli (1) *data_norm* predstavlja normalizovane podatke *data*, dok su *min_data* i *max_data* minimalna i maksimalna vrednost iz skupa podataka *data*, respektivno.

Ukupan skup podataka je podeljen na sledeći način: trening i validacioni skupovi čine 90% ukupnog skupa podataka, dok je za test podatke izdvojeno 10%. Trening i validacioni skup su podeljeni tako da je za trening skup uzeto 85%, a ostatak predstavlja validacioni skup. Dakle trening skup čini 76,5% ukupnih podataka, validacioni 13,5%, a test skup 10% ukupnih podataka. [2]. Model se trenira korišćenjem trening skupa. Funkcija cene (*cost function*) ili funkcija cilja, predstavlja kriterijum po kome će mreža biti trenirana. Korišćena funkcija cene u rešavanju ovog problema je MSE (*Mean Squared Error*). Ona predstavlja kvadrat razlike između očekivane (*target*) vrednosti i vrednosti koju je estimirala neuralna mreža. Prilikom obuke modela vrši se minimizacija funkcije cene. To praktično znači da bi greška na trening i validacionom skupu trebalo monotono da opada. Ocena kvaliteta modela vrši se na validacionom skupu podataka kako bi se izbegla pretreniranost (*overfitting*). Indikator koji ukazuje da je mreža pretrenirana je porast



Slika 2 Arhitektura neuralne mreže

greške na validacionom skupu podataka. Glavni zadatak mašinskog učenja je da balansira između optimizacije i generalizacije [8]. Optimizacija se odnosi na to da se parametri modela menjaju tokom treniranja mreže sa ciljem dobijanja najboljih mogućih performansi na trening podacima. Sa druge strane, generalizacija podrazumeva koliko obučeni model dobro radi za nepoznate ulazne podatke. Cilj je postići što veću generalizaciju [7], [2]. Da bi se performanse modela mogle pouzdano odrediti, potreban je skup podataka sa kojim se mreža nije susrela u fazi treniranja, što zapravo predstavlja test skup.

Prethodno opisana mreža je trenirana u 20 epoha. Jedna epoha se definiše jednim prolaskom kroz sve trening podatke u toku obuke. U okviru jedne epohe može postojati više iteracija. One definišu vrednost *mini-batch*-a. Nakon svake iteracije, težinski koeficijenti koje mreža treba da nauči se ažuriraju tako da se funkcija gubitka minimizuje [9]. Vrednost *mini-batch*-a u ovom slučaju je 64. Na ažuriranje težina utiče hiperparametar koji se zove *learning rate* [8]. Koeficijent *learning rate* iznosi 0.0001. Korišćen je optimizator *Adam* koji predstavlja jedan od algoritama sa adaptivnim *learning rate*-om [8]. Arhitektura je optimizovana za slučaj kada je $B = 100$ MHz i $\Delta f = 10$ kHz. Potom je ista arhitektura mreže korišćena i za sve ostale kombinacije širine radio kanala i frekvencijske rezolucije. Dodatne tehnike regularizacije nisu bile upotrebljene budući da mreža nije pretrenirana za predloženu arhitekturu i za zadate hiperparametre. Pokazatelj je greška na validacionom skupu koja opada u kontinuitetu u okviru korišćenog broja epoha za koje se mreža trenira.

V. REZULTATI

Na Sl. 3 (a-h) prikazani su rezultati predikcije PDP profila i vrednosti PDP profila dobijenih merenjem za izabrane širine kanala i frekvencijske rezolucije. Prvi i najistaknutiji pik na Sl. 3 (a-h) predstavlja direktnu komponentu, odnosno komponentu koja je prva stigla u prijemnik, dok ostali pikovi sa PDP grafika predstavljaju zakašnjene *multipath* komponente. Na Sl. 3 (a-h) uočava se da model dobro estimira

zakašnjene komponente. Uočava se i da za jako niske nivoe signala, estimirana vrednost slabo prati realne vrednosti. Međutim, ove vrednosti predstavljaju nivo šuma, zbog čega nisu od prevelikog interesa.

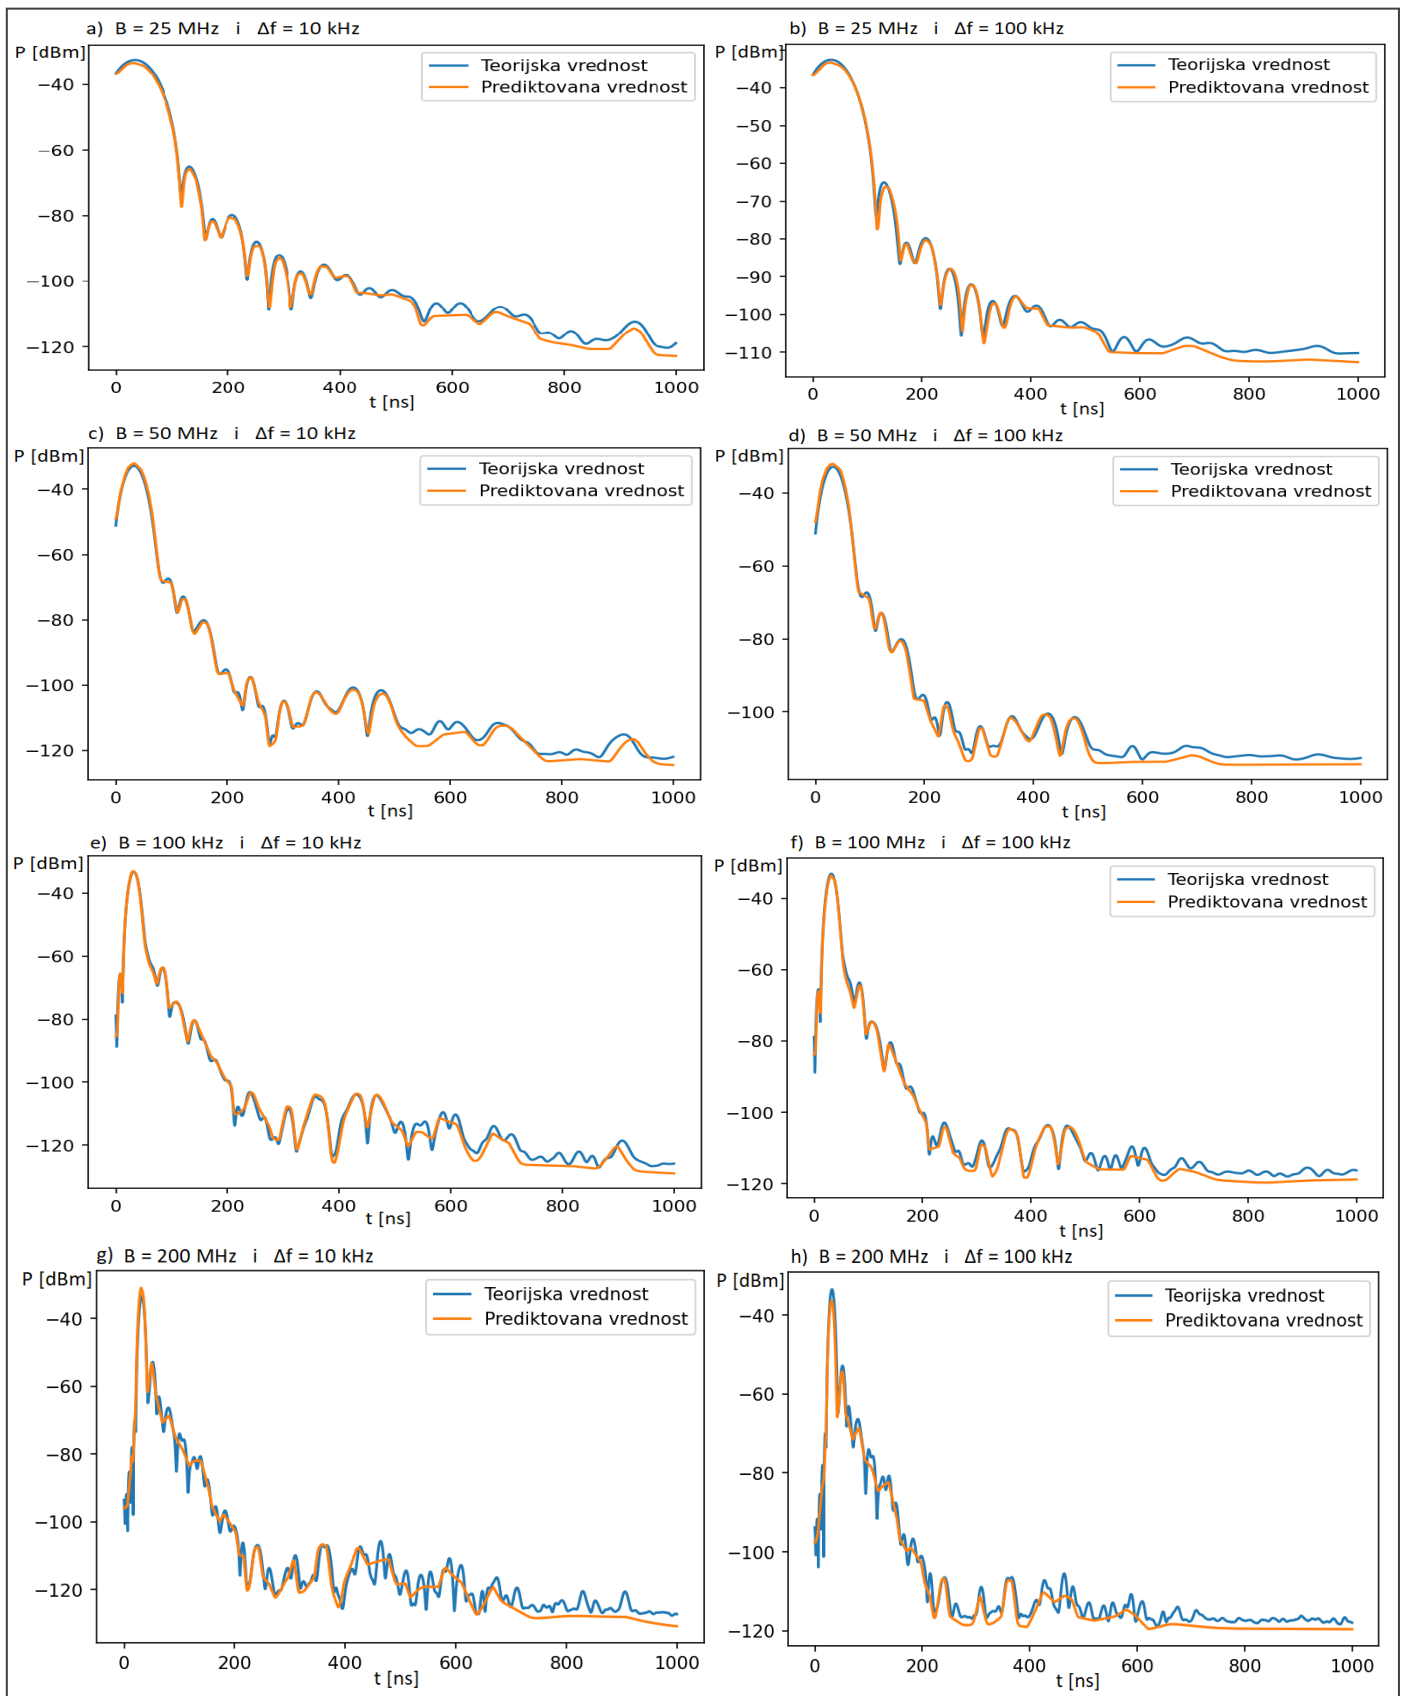
Na osnovu srednje kvadratne greške dobijene na odgovarajućim test podacima za svako merenje (Tabela 1), može se zaključiti da je korišćen model duboke neuralne mreže uspeo dobro da estimira PDP profil za sve kombinacije širine kanala i frekvencijske rezolucije. Pored toga, može se primetiti da je dominantna komponenta daleko veće snage u odnosu na ostale komponente višestruke propagacije, što je opet konzistentno sa prostornim razmeštajem predajne i prijemne antene i veličinom prostorije u kojoj su merenja obavljena kako je opisano u [6].

VI. ZAKLJUČAK

Tačna procena *multipath* komponenti veoma je važna za predikciju karakteristika *short-term fading*-a. Informacije o stanju u radio kanalu dobijene u realnom vremenu značajno utiču na poboljšanje performansi bežičnih komunikacionih sistema sa stanovišta protoka i pouzdanosti. Na osnovu PDP profila može se utvrditi broj značajnih *multipath* komponenti, njihova snaga, kao i kašnjenje u odnosu na komponentu koja je prva stigla u prijemnik. U radu je pokazano da korišćen model duboke MPL neuralne mreže dobro modeluje PDP profil za zadatu širinu kanala i frekvencijsku rezoluciju.

TABELA I. VREDNOSTI MSE DOBIJENE NA TEST PODACIMA IZRAŽENE U dB ZA DATU ŠIRINU KANALA I REZOLUCIJU

Širina radio kanala B [MHz]	Frekvencijska rezolucija	
	$\Delta f = 10$ kHz	$\Delta f = 100$ kHz
10	0.00210	0.00620
20	0.00333	0.00469
25	0.00087	0.00599
30	0.00461	0.00943
50	0.00202	0.00812
100	0.00537	0.00596
200	0.00931	0.00448



Slika 3 Prediktovane i teorijske vrednosti *Power Delay Profile*

LITERATURA

- [1] I. F. Akyildiz, A. Kak and S. Nie, "6G and Beyond: The Future of Wireless Communications Systems," *IEEE Access*, vol. 8, pp. 133995-134030, 2020
- [2] M. Burdžić, "Modelovanje impulsnog odziva radio kanala primenom neuralnih mreža," master rad
- [3] C. Huang *et al.*, "Artificial Intelligence Enabled Radio Propagation for Communications-Part II: Scenario Identification and Channel Modeling," in *IEEE Transactions on Antennas and Propagation*, vol. 70, no. 6, pp. 3955-3969, June 2022
- [4] M. Viswanathan, "Wireless Communication Systems in Matlab," Independently published, 2020
- [5] R. Shukla, A.N. Sarkar, A. Chandra, et a. "A simple ANN-MLP model for estimating 60-GHz PDP inside public and private vehicles," *J Wireless Com Network* 2023, 2023
- [6] D. Čoja, N. Nešković, A. Nešković, "Channel Impulse Response Estimation using Vector Network Analyzer," *TELFOR*, 2017
- [7] F. Chollet, "Deep learning with Python", Manning Publications, 2018
- [8] I. Goodfellow, Y. Bengio and Aaron Courville, "Deep Learning," MIT Press, 2016
- [9] P. Kim, "MATLAB Deep Learning: With Machine Learning, Neural Networks and Artificial Intelligence," Apress, 2017

ABSTRACT

Radio channel modeling is fundamental for designing wireless communication systems. Channel state information could be used for spatial multiplexing and beamforming techniques with the ultimate goal of increasing system capacity. Also, to improve the performance of wireless communication systems, it is important to accurately estimate the multipath components. For that purpose, Power Delay Profile – PDP is very important. The goal of this paper is to create an optimal model for PDP profile estimation using a Multilayer Perceptron (MLP) neural network, taking into account different bandwidths and frequency resolutions. It is concluded that the proposed architecture of the neural network enables a quality prediction.

Radio Channel Power Delay Profile Modeling using Neural Network

Marko Burdžić, Nataša Nešković, Aleksandar Nešković