

Pregled propagacionih modela zasnovanih na *deep learning* tehnikama

Jelena Mladenović, Aleksandar Nešković, Nataša Nešković

Elektrotehnički fakultet, Univerzitet u Beogradu

Beograd, Srbija

jelenam@etf.rs, an@etf.rs, natasha@etf.rs

Sažetak—Predstavljen je pregled propagacionih modela koji se zasnivaju na primeni *deep learning*-a, nastao kao rezultat istraživanja literature. Klasifikacija predstavljenih modela je izvršena na osnovu njihove mogućnosti da samostalno ili u kombinaciji sa nekim tradicionalnim modelom vrše predikciju. Analizirane su i osnovne razlike koje potiču od različitih *deep learning* modela i tipova ulaznih podataka korišćenih u procesu formiranja modela, a kasnije i same predikcije, kao i njihov uticaj na potrebu za ekspertskim znanjem u izboru podataka koji figurišu kao elementi u vektoru koji predstavlja ulaz u model.

Ključne reči - *deep learning*, *propagacioni model*, *radio propagacija*.


I. UVOD

Potreba za postojanjem propagacionih modela je stara koliko i prvi radio komunikacioni sistemi. Bez njih nije moguće savremeno planiranje i efikasno upravljanje bežičnim komunikacionim sistemima [1]. Stoga je kreiranje modela koji može da izvrši što tačniju predikciju, uz istovremeno održavanje numeričke efikasnosti, izazov koji je već decenijama aktuelan među ekspertima koji se bave propagacijom radio signala. Značaj propagacionih modela se ogleda u predikciji propagacionog slabljenja koje je jedna od osnovnih karakteristika propagacionog radio kanala, i predstavlja osnovu za analizu pokrivanja, određivanje nivoa snage signala koji se ostvaruje na prijemu, budžeta linka, odnosa signal-šum, ... [2], [3]. Tačna estimacija propagacionog slabljenja pruža osnovu za dobar izbor lokacija baznih stanica i ispravno frekventijsko planiranje, što predstavlja prvi korak u dizajniranju jednog radio sistema [2]. U literaturi je podela propagacionih modela uglavnom izvršena na determinističke i empirijske. Empirijski modeli se zasnivaju na opsežnim merenjima koja se sprovode u različitim okruženjima i različitim frekventijskim opsezima [4]. Njihova prednost se ogleda u tome da implicitno uzimaju u obzir uticaj okruženja na propagaciju signala, a nedostatak je po pravilu nedovoljna efikasnost koja zavisi od preciznosti merenja na osnovu kojih je model kreiran, ali i sličnosti između analiziranog i okruženja u kom je merenje sprovedeno [5]. Deterministički modeli se zasnivaju na zakonima fizike i generalno ih karakteriše veća preciznost od empirijskih. Njihov nedostatak se ogleda u lošoj numeričkoj efikasnosti i tome što zahtevaju opsežnu bazu podataka o okruženju, koju nekada nije moguće obezbediti. Uglavnom se koriste za predikciju u mikroćelijama i *indoor* okruženjima [5]. S obzirom na nedostatke koji postoje kod tradicionalnih, kako

empirijskih, tako i determinističkih modela, u literaturi je predložen veliki broj rešenja koja se zasnivaju na primeni savremenih tehnika mašinskog učenja i veštačke inteligencije. Razlog za popularnost primene pomenutih tehnika u kreiranju propagacionih modela je njihova mogućnost da efikasno aproksimiraju proizvoljnu funkciju koja se ne može eksplicitno opisati formulom i zavisna je od više ulaznih parametara, što odgovara problemu predikcije propagacionog slabljenja. Postoji relativno veliki broj rešenja za kreiranje propagacionih modela koja se zasnivaju na tehnikama veštačke inteligencije. U ovom radu je osvrtno napravljen na propagacione modele koji se zasnivaju na *deep learning*-u, koji predstavlja posebnu vrstu mašinskog učenja [6]. Prema dosadašnjim saznanjima autora, takvi modeli se zasnivaju na nadgledanom učenju i regresiji, uz izuzetak kada se ne radi tačna predikcija, već je cilj klasifikovati dobijenu vrednost u neku od kategorija koje ukazuju na nivo primljenog signala, kao što je predstavljeno u radu [7].


II. PRIMENA VEŠTAČKE INTELIGENCIJE U PROPAGACIONIM MODELIMA

Većina propagacionih modela predstavljenih u ovom radu se zasniva *deep feedforward* mrežama i konvolucionim mrežama ili nekim njihovim kombinovanim arhitekturama. *Deep feedforward* mreže su poznate i pod nazivom *feedforward neural networks* ili *multilayer perceptrons* (MLP) i predstavlja jedan od *deep learning* modela [6]. Arhitektura jedne *feedforward* neuralne mreže se sastoji iz jednog ulaznog, jednog izlaznog i više skrivenih slojeva. Skriveni slojevi se mogu posmatrati kao skup jedinica koje rade u paraleli i predstavljaju funkciju koja vrši preslikavanje iz vektora u skalar [6]. Svaka jedinica se može posmatrati kao neuron koji prima informacije od više neurona koji potiču iz prethodnog sloja i na osnovu tih informacija računa svoj izlaz [6]. Vrednost dobijenog izlaza u značajnoj meri zavisi i od izbora aktivacione funkcije koja je neophodna za razumevanje kompleksnih nelinearnih funkcija. Bez njihove primene izlazni signal bi bio samo jednostavna linearna funkcija [8]. Aktivaciona funkcija neurona mapira bilo koju ulaznu vrednost na odgovarajući izlaz iz definisanog opsega. Primeri aktivacionih funkcija su *tanh*, *sigmoid*, *softsign*, *softplus*, *softmax*, *ReLU* (*Rectified Linear Unit*) [8]. Veoma je česta primena ReLU aktivacione funkcije zbog njene prednosti koja se ogleda u jednostavnosti i tome što se njenim izborom eliminiše *vanishing gradient* problem [9], Sl. 1.



Slika 1. ReLU aktivaciona funkcija [8]


Broj skrivenih slojeva u arhitekturi jedne MLP mreže ukazuje na njenu dubinu (eng. *depth*), a broj jedinica u skrivenim slojevima na njenu širinu (eng. *width*) [6]. Kada je broj skrivenih slojeva mali, tada se govori o *shallow* neuralnim mrežama. Svaka od ovih arhitektura ima prednosti za određeni tip problema [10]. Kada je u pitanju kreiranje propagacionih modela, većina modela podrazumeva arhitekturu sa većim brojem skrivenih slojeva, odnosno *deep feedforward* mreže. *Feedforward* u nazivu ukazuje na to da ovakve mreže nemaju povratne veze u arhitekturi, već da informacija putuje u jednom smeru, Sl.2.



Slika 2. Primer arhitekture *feedforward* neuralne mreže

Kada povratne veze postoje, tada se govori o rekurentnim neuralnim mrežama, koje nisu razmatrane u ovom pregledu. Kod propagacionih modela koji se zasnivaju na MLP mrežama, ulaze čine vektori sa podacima koji su nastali kao rezultat odabira eksperata koji formiraju model, od kojih u velikoj meri zavise i performanse ovakvih modela. Stoga je značajno napraviti pravilan izbor, vodeći računa o dimenzionalnosti ulaznog vektora i mogućoj korelaciji između različitih podataka za treniranje modela, odnosno, elemenata u ulaznom vektoru.

Za razliku od *feedforward*, konvolucione mreže predstavljaju posebnu vrstu neuralnih mreža za podatke koji imaju topologiju mreže [6]. Najčešće, i ono što je osnovna tema istraživanja ovog rada, ti podaci su predstavljeni u formi slike, odnosno matrice sa pikselima. Arhitektura svake konvolucione neuralne mreže se sastoji iz više slojeva koji imaju različite funkcije, kao što su konvolucioni, *pooling* i *fully connected* slojevi, Sl 3.



Slika 3. Primer konvolucione neuralne mreže

Ono što je, između ostalog, značajna razlika kod ovakvih mreža u odnosu na prethodno pomenute *feedforward* jeste mogućnost da se kroz različite slojeve, kao što su konvolucioni, *pooling*, *fully connected* slojevi, iz slike samostalno odrede karakteristike bitne za rešavanje zadatka od interesa. Ti zadaci su najčešće u domenu klasifikacije slike, premda postoje i primeri kada se konvolucione neuralne mreže koriste za *image-driven* regresiju [11], kao što je to slučaj kod kreiranja propagacionih modela koji za cilj imaju da na osnovu slika sa informacijama značajnim za propagaciju radio signala kao ulaznim podacima, izvrše što tačniju predikciju.

Pojedini autori u svojim radovima pored performanse kreiranog modela zasnovanog na veštačkim neuralnim mrežama sa performansama nekog tradicionalnog modela. Autori u [12] su predstavili poboljšanje RMSE (*Root Mean Square Error*) ostvareno sa njihovim rešenjem u odnosu na ITU 452 [13] i Cost-Hata model [12] koje iznosi oko 7 dB i 9 dB, respektivno, dok je u poređenju sa *ray-tracing* pristupom u modelovanju ostvareno smanjenje u trajanju predikcije čak 12 puta. Bolje performanse su zabeležene i u poređenju sa CI PL [4] i A-B PL [4] modelom, što je predstavljeno u [4]. Poređenje sa *Ray-Tracing* i UMa (*urban macro*) 38.901 modelom [14] na 811 MHz i 2630 MHz je predstavljeno u radu [15], gde poboljšanje predstavljenog modela zasnovanog na *deep learning*-u, u poređenju sa prethodno pomenutim tradicionalnim modelima iznosi i do 4.7 dB. U Tabeli I je prikazan pregled modela predstavljenih u literaturi na osnovu koje je izvršena analiza prikazana u ovom radu. Kod radova u kojima je predstavljena detaljnija analiza vršena nad više arhitektura, u Tabeli I su predstavljeni najbolji rezultati ostvareni za proizvoljno izabrani statistički parametar, ukoliko ih je bilo više.

III. SAMOSTALNI ANN MODELI

Kao što je već spomenuto u prethodnom poglavlju, izborom tipa neuralne mreže i ulaznih podataka moguće je razlikovati modele poput onih koji se zasnivaju na MLP mrežama [2]–[4], [12], [16], [17] kod kojih ulaz čini vektor sa elementima nastalim kao odabir eksperata koji kreiraju model i modele koji koriste sirove podatke, što mogu biti slike kod konvolucionih mreža [11], [15], [18]–[22] ili sirovi merni podaci u slučaju GAN (*Generative Adversarial Networks*) mreža [23].

U literaturi je predložen veliki broj propagacionih modela koji se zasnivaju na MLP neuralnim mrežama i koji kroz izbor elemenata u ulaznom vektoru razmatraju različite uticaje na propagaciju. S obzirom na značaj okruženja na propagaciju signala, prilikom kreiranja propagacionog modela veoma je važno razmotriti njegov uticaj, što kod modela koji se

zasnivaju na MLP mrežama podrazumeva adekvatan izbor elemenata u ulaznom vektoru. Kada se opisuje propagaciono okruženje u urbanoj sredini, uticaj zgrada i ulica na propagaciju može biti veliki. Tako je u radu [2] razmatran broj i procenat zgrada na pravcu signala, kao i informacije koje se odnose na glavnu i poprečne ulice. Informacije se mogu odnositi i na uticaj zgrada kroz posmatranje broja zgrada kroz koje signal prolazi na direktnoj putanji između predajnika i prijemnika u svakom od klatera, gde različiti klateri mogu biti različiti tipovi zgrada [12]. U okviru rada [17] uticaj zgrada je analiziran time što je putanja između predajnika i prijemnika izdvojena na proizvoljan broj intervala, gde se unutar svakog od njih određuje zgrada sa najvećom visinom iznad linije direktne optičke vidljivosti i opisuje parametrima kao što su visina iznad linije direktne optičke vidljivosti, udaljenost od predajnika i širina. Autori u radu [16] uticaj zgrada i ulica razmatraju tako što oblast od interesa dele na mrežu $N \times N$ ćelija, gde centar svake od ćelija leži na ulici ili zgradi u zavisnosti od raspodele zgrada, pri čemu se zgrade opisuju širinom, visinom i dužinom, a ulica širinom.

Kada se opisuje uticaj propagacionog okruženja, u nedostatku informacija o njegovoj geometriji i materijalima, kao informacije se mogu koristiti tipovi okruženja (zelene površine, šume, visoke zgrade, more, vlažno zemljište...) [4]. Pokazalo se da razmatranje informacija o okruženju prilikom kreiranja propagacionog modela doprinosi tačnosti predikcije [4], [7]. Uzimanjem u obzir pomenutih informacija, u radovima [4], [7] je zamena za složeno 3D modelovanje ostvarena formiranjem vektora čije dimenzije odgovaraju broju razmatranih tipova okruženja. Svaki element vektora odgovara dužini linije na LoS (*Line of Sight*) pravcu koja prolazi kroz odgovarajući tip okruženja. Elementi vektora koji opisuju okruženje mogu biti i brojevi pojavljivanja svakog od tipova okruženja unutar pravougaonika čija su temena po dijagonali pozicije predajnika i prijemnika [4]. Postoje primeri gde se razmatraju upotreba terena i gustina vegetacije [24]. Značajne informacije su i parametri sistema koji se odnose na frekvenciju, informacije o antenama, pozicijama predajnika i prijemnika koje mogu biti predstavljene i latitudom i longitudom [25], rastojanje predajnika i prijemnika, kao i informacije o tome da li su zadovoljeni uslovi direktne optičke vidljivosti [12]. Kao što je napomenuto ranije, formiranje ulaznog vektora može biti veoma zahtevno. Potrebno je uzeti u obzir informacije koje na najbolji način opisuju uticaj propagacionog okruženja i parametara sistema na predikciju i obezbeđuju dobre generalizacione osobine. Pri tome je potrebno voditi računa o dimenzijama vektora i korelaciji koja može da postoji između elemenata vektora kojima su predstavljene informacije od interesa. U cilju redukcije dimenzija ulaznog vektora, uz zadržavanje značajnih informacija, primenjuje se PCA (*Principal Component Analysis*) tehnika. Smanjenjem dimenzija PCA doprinosi i većoj brzini obučavanja mreže i poboljšanju generalizacionih osobina modela [3]. Primenjena je u radovima [4], [7] u cilju redukovanja linearne korelacije između različitih tipova okruženja. Analiza u radu [17] je pokazala da se bolji rezultati dobijaju kada se nad ulaznim vektorom primeni PCA.

Konvolucione neuralne mreže podrazumevaju primenu slika kao ulaznih podataka. Primeri upotrebe slika kao ulaza

propagacionog modela mogu biti slike sa informacijama o okruženju, poput npr. aero snimaka [19], [20] koje sadrže značajne informacije o zgradama, putevima i vegetaciji i kao takve obezbeđuju značajne informacije za ispitivanje uticaja okruženja na propagaciju u urbanoj sredini. Stoga je u [17] kao ulaz u mrežu, između ostalog, posmatrana i jedna takva *gray-scale* slika sa centrom na poziciji predajnika ili prijemnika, dimenzija 256×256 , gde vrednost svakog piksela odgovara oblasti $1 \text{ m} \times 1 \text{ m}$. Takođe, vrednosti piksela slike koja se koristi kao ulaz u model mogu predstavljati bilo koju informaciju, pa tako mogu ukazivati na visine profila terena [21], [22], visinu zgrada [19] i slično. U radu [19] je kreirana slika sa informacijama o zgradama gde su jasno izdvojeni delovi koji predstavljaju objekte i putevi. Pokazalo se da se upotrebom takvih slika zajedno sa slikama koje daju informaciju o visinama zgrada postiže manja greška u predikciji nego kada se kao ulaz koriste slike sa satelitskim snimcima. S obzirom na ograničenost postajanja aero snimaka sa informacijama o zgradama unutar jedne urbane oblasti, u radu [20] je dato unapređenje modela predstavljenog u [19] za slučaj kada su na raspolaganju samo satelitski snimci. Predstavljeno rešenje podrazumeva kreiranje slika od interesa sa informacijama o zgradama na osnovu satelitskih snimaka primenom UNET mreža [26], koje se kasnije koriste kao ulaz u model. Ispitivan je i uticaj veličine slike na kompleksnost modela i tačnost predikcije. Analiza u [19] je pokazala 93% redukcije kompleksnosti kada se dimenzije slike smanje sa 256×256 na 64×64 , uz narušavanje RMSE za 1 dB. Takođe, uticaj dimenzija slike na ostvarene performanse je ispitivan i u [11], kroz poređenje ostvarene MAE (*Mean Absolute Error*) za slučaj kada se odabrane dimenzije slike od 64×64 piksela porede sa dimenzijama slika od 16×16 , 32×32 , 128×128 i 256×256 piksela. Pokazalo se da je smanjenje dimenzija slike rezultovalo lošijom estimacijom, dok značajno povećanje dimenzija slike nije imalo velikog uticaja na poboljšanje. Razmatranje uticaja zgrada u [11], podrazumeva kao ulaz u konvolucionu mrežu sliku sa visinama zgrada, koja predstavlja pravougaonu oblast u čijim temenima po dijagonali se nalaze predajnik i prijemnik. U zavisnosti od rastojanja predajnika i prijemnika, razlikuju se i dimenzije kreirane slike sa visinama zgrada u području od interesa. Svaka slika se pre dovođenja na ulaz u konvolucionu mrežu svodi na predefinisane dimenzije kvadrata. Promenom dimenzija slike ne gubi se informacija o rastojanju koja je sadržana u slici [11]. Većina modela koji se zasnivaju na konvolucionim neuralnim mrežama, pored slika, kao ulaze razmatra i informacije koje nisu u formi slike i koji su uglavnom predstavljeni skalarom ili vektorom sa karakteristikama. Takve dodatne informacije uglavnom ukazuju na rastojanje [21] i parametre sistema, kao što su orijentacija, tilt i dobitak antene, visina predajnika i druge [19].

Pored konvolucionih neuralnih mreža, GAN mreže takođe omogućuju kreiranje modela bez vektora sa ulaznim podacima za čije kreiranje je potrebno ekspertsko znanje iz oblasti propagacije radio signala. U [23] se koristi koncept GAN mreže koja se trenira sirovim mernim podacima za specifičan scenario. Sastoji se iz dve neuralne mreže, pri čemu je jedna generator (*Channel Data Generator*), a druga diskriminator (*Channel Data Discriminator*).

TABELA I.

UPOREDNI PRIKAZ MODELA PREDSTAVLJENIH U LITERATURI

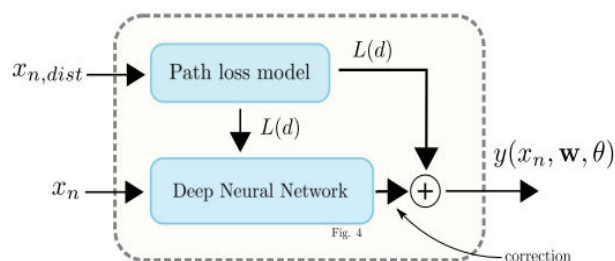
Referenca	Tip neuralne mreže	Učehće eksperata u odabiru elemenata ulaznog vektora	Redukcija dimenzija	Samostalan/kombinovani	Tip greške za evaluaciju	Vrednost greške
[2]	MLP	Da	Ne	Samostalan	RMSE	4.85 dB
[3]	MLP	Da	Da	Samostalan	RMSE	7.87 dB
[4]	MLP	Da	Da	Samostalan	MAE	< 3.64 dB
[11]	CNN	Ne	Ne	Samostalan	RMSE	4.42 dB
[12]	MLP	Da	Ne	Samostalan	RMSE	6.19 dB
[15]	CNN+MLP	Delimično	Ne	Kombinovani	RMSE	≈ 4.5 dB
[16]	MLP	Da	Ne	Samostalan	MEAN	4.89 dB
[17]	MLP	Da	Da	Samostalan	MSE	51.15 dB ²
[18]	CNN+MLP	Delimično	Ne	Kombinovani	RMSE	6.3 dB
[19]	CNN	Delimično	Ne	Samostalan	RMSE	≈ 4 dB
[20]	CNN	Delimično	Ne	Samostalan	RMSE	7.54 dB
[21]	CNN	Ne	Ne	Samostalan	RMSE	4.9 dB
[22]	CNN	Ne	Ne	Samostalan	RMSE	6.65 dB
[23]	GAN	Ne	Ne	Samostalan	/	/

Generator pokušava da generiše što realnije odbirke poput onih dobijenih iz mernih kampanja, čime direktno uči karakteristike ciljanog radio kanala. Diskriminator predstavlja drugu neuralnu mrežu koja se trenira sa ciljem da što efikasnije razlikuje realne odbirke od lažnih, odnosno, generisanih od strane generatora. Kroz nadmetanje ove dve mreže, kreira se model kanala. Trening se zaustavlja onda kada diskriminator više nije u mogućnosti da razlikuje lažne odbirke od realnih, i tada se generator izdvaja kao model kanala. Nedostatak ovog modela je u potrebi za zahtevnim i opsežnim merenjima, kao i mogući problemi sa konvergencijom. Generator može pronaći jedan tip odbiraka kojim uspeva da prevazi diskriminatora i da samo pravi varijacije na taj odbirak, bez da uči da generiše različite odbirke. Takođe, ovakav model je specifičan za okruženje u kom je sprovedena merna kampanja [23].

IV. KOMBINOVANI TRADICIONALNI I ANN MODELI

Za razliku od prethodno predstavljenih modela radio kanala koji su u potpunosti zasnovani na neuralnim mrežama, postoje i oni koji su kombinovani sa nekim tradicionalnim modelima. Ovakvi modeli se ne zasnivaju samo na podacima, već koriste i asistenciju jednostavnijih modela u učenju [15]. Primer takvog modela je predstavljen u [15] gde se u procesu učenja koristi jednostavan propagacioni model. Predstavljeni model kao ulaz u mrežu pored vektora koji sadrži informacije o koordinatama prijemnika, rastojanjima u pravcu latituda i longitude, rastojanju vazdušnom linijom i satelitske slike, koristi i rezultat tzv. Uma_B modela [14]. Izlaz Uma_B modela se takođe dovodi i na izlaz iz mreže, Sl. 4. Na ovaj

način je ostvareno da model uči korekciju koja se dodaje na vrednost dobijenu primenom tradicionalnog modela.



Slika 4. Šema funkcionisanja kombinovanog modela [15]

Arhitektura pomenutog modela se sastoji iz dve neuralne i jedne konvolucione mreže, koja služi za procesiranje satelitskih slika. Izlazi jedne neuralne mreže i konvolucione mreže se dovode na ulaz druge neuralne mreže koja je direktno povezana sa izlazom. Pokazalo se da se najbolji rezultati dobijaju u slučaju kada se učenje obavlja uz asistenciju tradicionalnog modela, pri čemu se uz ulazni vektor koriste i satelitski snimci [15].

Slična arhitektura modela je predstavljen i u radu [18] koji predstavlja proširenje rada [15], sa razlikama koje se odnose na ulazne parametre i kompleksnost modela. Model predstavljen u [18] je kombinovan sa 3GPP UMa [27] modelom i koristi OSM (*Open Street Map*) slike. Kreirani model pokazuje slične performanse kao [15] uz značajno smanjenje kompleksnosti modela.

V. ZAKLJUČAK

U ovom radu je dat pregled određenog broja propagacionih modela predstavljenih u literaturi koji se zasnivaju na *deep learning*-u. Prikazana su samostalna rešenja koja se u potpunosti zasnivaju na nekoj *deep learning* arhitekturi, kao i ona koja zajedno sa *deep learning* rešenjem kombinuju i primenu nekog tradicionalnog modela. Analizirane su različite arhitekture modela sa posebnim osvrtom na ulazne podatke koji se korsite za kreiranje modela. Prvi takvi propagacioni modeli su se zasnivali na MLP mrežama koje su zavisne od izbora parametara korišćenih u predikciji i nastalih kao odabir eksperata koji formiraju model. Većina radova novijeg datuma teži kreiranju modela visokih performansi koji će se što manje oslanjati na ekspertsko znanje i time smanjiti greške u predikciji koje mogu biti posledica uticaja ljudskog faktora.

LITERATURA

- [1] A. Seretis and C. D. Sarris, "An overview of machine learning techniques for radiowave propagation modeling," in *IEEE Transactions on Antennas and Propagation*, July 2021.
- [2] A. Nešković, N. Nešković, "Microcell electric field strength prediction model based upon artificial neural networks," *AEU-INTERNATIONAL JOURNAL OF ELECTRONICS AND COMMUNICATIONS*, Vol. 64, No. 8, pp. 733 - 738, Aug. 2010.
- [3] H.-S. Jo, C. Park, E. Lee, H. K. Choi, and J. Park, "Path loss prediction based on machine learning techniques: Principal component analysis, artificial neural network, and gaussian process," *Sensors*, vol. 20, no. 7, p. 1927, Mar. 2020.
- [4] L. Wu, D. He, B. Ai, J. Wang, H. Qi, K. Guan, Z. Zhong, "Artificial neural network based path loss prediction for wireless communication network," in *IEEE Access*, vol. 8, pp. 199523-199538, 2020.
- [5] I. Popescu, I. Nafornita and P. Constantinou, "Comparison of neural network models for path loss prediction," *WiMob'2005, IEEE International Conference on Wireless And Mobile Computing, Networking And Communications, 2005.*, pp. 44-49 Vol. 1, 2005.
- [6] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [7] L. Wu, D. He, K. Guan, B. Ai, C. Briso-Rodriguez, T. Shui, C. Liu, L. Zhu, and X. Shen, "Received power prediction for suburban environment based on neural network," in *Proc. Int. Conf. Inf. Netw. (ICOIN)*, Jan. 2020, pp. 35-39.
- [8] HCIA-Artificial Intelligence MOOC, Huawei, prezentacija, 2020.
- [9] S. Albawi, T. A. Mohammed and S. Al-Zawi, "Understanding of a convolutional neural network," *2017 International Conference on Engineering and Technology (ICET)*, pp. 1-6, 2017.
- [10] D. E. Kim and M. Gofman, "Comparison of shallow and deep neural networks for network intrusion detection," *2018 IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC)*, 2018, pp. 204-208.
- [11] Sotirios P. Sotiroidis, Sotirios K. Goudos, Katherine Siakavara, "Deep learning for radio propagation: Using image-driven regression to estimate path loss in urban areas," *ICT Express*, Volume 6, Issue 3, 2020, pp. 160-165.
- [12] U. Masood, H. Farooq, A. Imran, "A machine learning based 3D propagation model for intelligent future cellular networks," *GLOBECOM 2019 - 2019 IEEE Global*.
- [13] ITU-R Recommendation P.452-15, "Prediction procedure for the evaluation of interference between stations on the surface of the Earth at frequencies above about 0.1 GHz," ITU, Geneva, 2013.
- [14] TR 138 901 - V14.3.0 - 5G; Study on Channel Model for Frequencies From 0.5 to 100 GHz, 3GPP document TR 38.901 version 14.3.0 Release 14. [Online]. Available: <http://www.etsi.org/standards-search>
- [15] J. Thrane, D. Zibar and H. L. Christiansen, "Model-Aided deep learning method for path loss prediction in mobile communication systems at 2.6 GHz," in *IEEE Access*, vol. 8, 2020, pp. 7925-7936.
- [16] S. Sotiroidis, K. Siakavara, J.N. Sahalos, "A neural network approach to the prediction of the propagation path-loss for mobile communications systems in urban environments," *Piers Online*. 3. pp. 1175-1179, 2007.
- [17] M. Piacentini, F. Rinaldi, "Path loss prediction in urban environment using learning machines and dimensionality reduction techniques," *Comput Manag Sci* 8, 2011, pp. 371-385.
- [18] J. Thrane, B. Sliwa, C. Wietfeld and H. L. Christiansen, "Deep learning-based signal strength prediction using geographical images and expert knowledge," *GLOBECOM 2020 - 2020 IEEE Global Communications Conference*, 2020, pp. 1-6.
- [19] T. Hayashi, T. Nagao and S. Ito, "A study on the variety and size of input data for radio propagation prediction using a deep neural network," *2020 14th European Conference on Antennas and Propagation (EuCAP)*, 2020, pp. 1-5.
- [20] K. Inoue, K. Ichige, T. Nagao and T. Hayashi, "Radio propagation prediction using neural network and building occupancy estimation," *2020 International Symposium on Antennas and Propagation (ISAP)*, 2021, pp. 315-316.
- [21] M. Ribero, R. W. Heath, H. Vikalo, D. Chizhik and R. A. Valenzuela, "Deep learning propagation models over irregular terrain," *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019, pp. 4519-4523.
- [22] J. Mladenović, A. Nešković and N. Nešković, "Primena deep learning-a za potrebe predikcije nivoa snage signala u mobilnim radio mrežama," *2021 29th Telecommunications Forum (TELFOR)*, 2021, pp. 1-4.
- [23] Y. Yang, Y. Li, W. Zhang, F. Qin, P. Zhu and C. -X. Wang, "Generative-Adversarial-Network-Based wireless channel modeling: challenges and opportunities," in *IEEE Communications Magazine*, vol. 57, no. 3, pp. 22-27, March 2019.
- [24] E. Ostlin, H. Zepernick and H. Suzuki, "Macrocell path-loss prediction using artificial neural networks," in *IEEE Transactions on Vehicular Technology*, vol. 59, no. 6, pp. 2735-2747, July 2010.
- [25] S. Popoola, A. Jafia, Prof. A. Atayero, O. Kingsley, N. Faruk, O. F. Oseni, R. Abolade, "Determination of neural network parameters for path loss prediction in very high frequency wireless channel," *IEEE Access*, 7:1-1, 2019.
- [26] O. Ronneberger, O. Fischer, and T. Brox, "U-Net: Convolutional networks for biomedical image segmentation," in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (N. Navab, J. Hornegger, W. M. Wells, and A. F. Frangi, eds.), (Cham), pp. 234-241, Springer International Publishing, 2015
- [27] 3GPP, "3GPP TR 38.901 - 5G; Study on channel model for frequencies from 0.5 to 100 GHz," 3rd Generation Partnership Project (3GPP), Tech. Rep. 38.901, Dec 2019, version 16.1.0.

ABSTRACT

In this paper, a literature overview of propagation models based on the application of deep learning is presented. The classification of the presented models is based on their ability to make predictions independently or combined with a traditional model. The basic differences arising from different deep learning models and types of input data are analyzed, as well as their impact on the need for expert knowledge in the selection of data that appear as elements in the vector representing input.

AN OVERVIEW OF PROPAGATION MODELS BASED ON DEEP LEARNING TECHNIQUES

Jelena Mladenovic, Aleksandar Neskovic, Natasa Neskovic