

Predikcija nivoa snage signala u mobilnim radio mrežama zasnovana na U-Net mreži

Jelena Mladenović, Aleksandar Nešković, Nataša Nešković

Elektrotehnički fakultet, Univerzitet u Beogradu

Beograd, Srbija

jelenam@etf.rs, neshko@etf.rs, natasha@etf.rs

Sažetak—U radu je predstavljen model za predikciju nivoa snage signala koji se zasniva na primeni *deep learning-a*, konkretno, na U-Net mreži. Predloženi model omogućuje predikciju nivoa snage signala u makročeliji na osnovu slike reljefa kao ulaznog podatka. Rezultat je mapa sa nivoom snage signala za zadatu makročeliju. Predikcija za 428 testnih makročelijskih lokacija obezbeđuje se za nekoliko sekundi sa tačnošću od 7.3652 dB, kada se kao statistički parameter posmatra RMSE (*root mean squared error*) usrednjena po svim lokacijama.

Ključne reči-predikcija; mobilne radio mreže; makročelija; deep learning;

I. UVOD

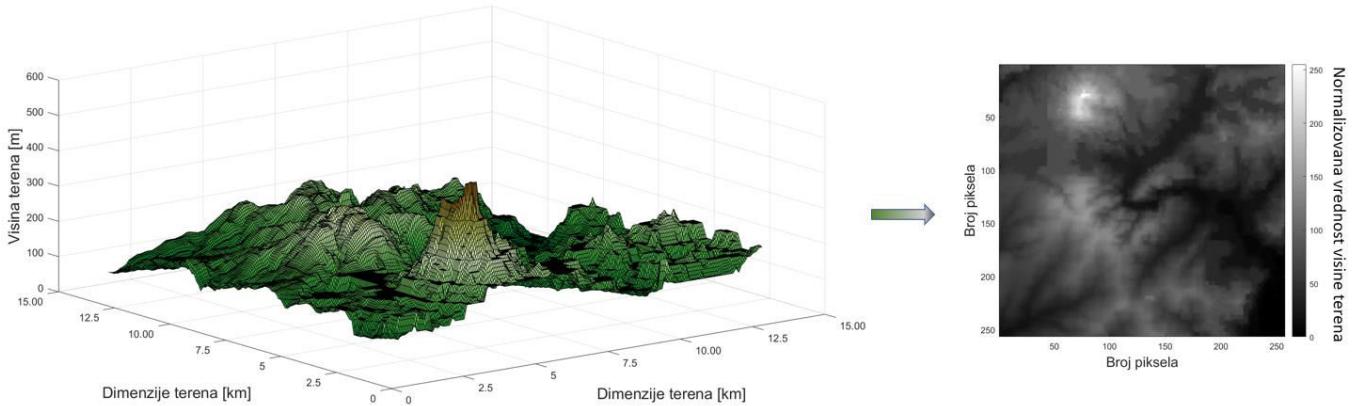
Bežične komunikacione mreže poslednjih godina beleže ubrzani razvoj. Jedan od razloga je sve veći broj ne samo korisnika, nego i broja uređaja po korisniku. U skladu sa tim se znatno povećavaju potrebe za različitim servisima, a zahtevi u pogledu protoka i kvaliteta servisa postaju sve veći. Da bi se izšlo u susret, kako navedenim, tako i mnogim drugim zahtevima koji se postavljaju pred bežične komunikacione mreže, potrebno je unapređivati postojeće tehnologije i omogućiti infrastrukturu koja te zahteve može da iznese. Propagaciono slabljenje signala je jedan od kritičnih faktora kada se formira i optimizuje bežična komunikacione mreža [1]. Propagaciono slabljenje zavisi od velikog broja faktora, a na njegovu vrednost utiču mehanizmi prostiranja signala kao što su refleksija, difrakcija, refrakcija itd. Odnosno, propagaciono slabljenje je funkcija velikog broja faktora koja se ne može predstaviti analitički. Stoga je kreiranje modela koji što je moguće tačnije i efikasnije vrši njegovu predikciju tema interesovanja, kako istraživača, tako i mobilnih operatera jer predstavlja osnovu za analizu pokrivanja signalom teritorije od značaja, određivanje budžeta linka i lokacija baznih stanica [2]. Pored tradicionalnih empirijskih i statističkih modela čiji se nedostaci ogledaju u kompromisu koji se pravi između tačnosti i numeričke efikasnosti, u novije vreme sve češće se ispituju načini na koje se savremene tehnike mašinskog učenja i veštacke inteligencije mogu iskoristiti za kreiranje propagacionih modela. Stoga se u literaturi mogu pronaći rešenja za kreiranje propagacionih modela koja se oslanjaju na MLP (*multilayer perceptrons*) [2], [3], [4], CNN (*convolutional neural network*) [5], [6], [7], GAN (*generative adversarial networks*) [8] i druge arhitekture veštackih neuralnih mreža.

U okviru ovog rada će biti predstavljen propagacioni model koji se zasniva na primeni U-Net mreže [9] koja predstavlja poseban tip konvolucione neuralne mreže. Razlog ovakvog izbora arhitekture neuralne mreže je ideja autora da se kreira propagacioni model koji će samostalno, na osnovu slike reljefa terena, vršiti predikciju signala za datu teritoriju, i rezultat predikcije, takođe, predstaviti u formi slike. Time se znatno smanjuje uticaj ljudske greške na tačnost predikcije nivoa snage signala. Kod arhitektura neuralnih mreža kao što je MLP, tačnost modela je u velikoj meri određena stručnošću eksperta da odredi koje karakteristike utiču na propagaciono slabljenje signala, odnosno, nivo snage signala koji se dobija na prijemu. Kod predikcionih modela koji se zasnivaju na principu predstavljenom u ovom radu, dovoljno je da se mreži obezbede odgovarajuće slike kao ulazni podaci, na osnovu kojih ona sama uči način na koji one utiču na nivo snage signala koji se ostvaruje na prijemu. Primeri primene U-Net arhitekture za kreiranje propagacionog modela već postoje u literaturi [10], [1]. Jedna od osnovnih razlika propagacionog modela predstavljenog u ovom radu u odnosu na postojeće je što se postojeći modeli odnose na predikciju u urbanom okruženju za celije manjih dimenzija. Razmatranjem urbanog okruženja u obzir se uzimaju slike gde se zgrade predstavljaju kao blokovi. Te slike mogu biti binarne (vrednost piksela gde zgrada postoji je jedan, a van nje je nula) [10] ili mogu imati vrednosti iz realnog opsega visine zgrada [1]. U svakom slučaju, opseg razmatranih visina je znatno manji nego u slučaju kada se razmatra reljef. Visine terena na osnovu kojih su formirane slike sa reljefom u ovom radu su u opsegu od 50 m do 2017 m.

Rad je organizovan na sledeći način. Ulagani podaci neophodni za formiranje modela predikcije nivoa snage signala definisani su u II poglavljju. Opis arhitekture U-Net mreže dat je u poglavljju III. Način na koji je sprovedeno treniranje, validacija i testiranje predloženog modela predikcije objašnjen je u poglavljju IV. Rezultati predikcije i procena tačnosti kreiranog modela izloženi su u poglavljvu V. Predlozi za dalja unapređenja predloženog modela predikcije dati su u okviru Zaključka.

II. PODACI ZA FORMIRANJE MODELAA

Model za predikciju predstavljen u ovom radu ima za cilj predikciju nivoa snage signala na teritoriji od interesa na osnovu visine terena na dатој teritoriji. Odnosno, dobijanje slike sa nivoom snage signala na teritoriju od interesa na



Slika 1. Formiranje slike reljefa terena

osnovu slike reljefa date teritorije kao ulaznog podatka. 2D slike reljefa terena koje se koriste kao ulazni podaci su formirane na osnovu matrica sa visinama terena. Razmatrane slike su dimenzija 256×256 piksela, gde svaki piksel predstavlja oblast $50\text{ m} \times 50\text{ m}$. Time je omogućeno razmatranje oblasti dimenzija $12.8\text{ km} \times 12.8\text{ km}$, što odgovara dimenzijama jedne makroćelije. Vrednosti piksela slike sa reljefom odgovaraju visinama terena normalizovanim tako da su u opsegu vrednosti koje piksel može da ima, tj. od 0 do 255, Sl.1.

Kod nadgledanog učenja (*supervised learning*) targeti predstavljaju tačne vrednosti koje se pridružuju ulaznim podacima radi formiranja ulazno-izlaznih parova na osnovu kojih se mreža obučava. U predstavljenom radu ulazno-izlazne parove čine slike reljefa makroćelijskih lokacija i odgovarajuće slike nivoa snage signala. Za formiranje targeta se koriste vrednosti nivoa snage signala dobijene primenom jednostavnog teorijskog modela koji prilikom proračuna razmatra slabljenje signala u slobodnom prostoru i slabljenje usled difracije [11], [12]. Svaki piksel u slici nivoa snage signala u realnosti predstavlja srednju vrednost nivoa snage signala na teritoriji kojoj odgovaraju dimenzije $50\text{ m} \times 50\text{ m}$. Prilikom proračuna nivoa snage signala pozicija predajnika je postavljena u centru razmatrane oblasti. Karakteristike predajnika i prijemnika korišćene u proračunu su predstavljene u Tabeli 1.

TABELA I. KARAKTERISTIKE PREDAJNIKA I PRIJEMNIKA

Predajna snaga [dBm]	32
Radna učestanost [MHz]	700
Osetljivost prijemnika [dBm]	-100
Visina predajne antene [m]	30
Visina prijemne antene [m]	1.5
Dobitak predajne antene [dBi]	2.15
Dobitak prijemne antene [dBi]	2.15

Vrednosti nivoa snage signala za svaku oblast se nalaze u opsegu od -100 dBm do -21 dBm . Minimalna vrednost nivoa snage signala odgovara osetljivosti prijemnika i izabrana je u skladu sa [13]. Maksimalna vrednost odgovara tački koja je najbliža predajniku u proračunu, u slučaju kada nema prepreke, već se razmatra samo propagaciono slabljenje. Vrednosti dobijene primenom teorijskog modela se normalizuju kako bi bile u opsegu vrednosti koje piksel može da ima, na osnovu čega se formira 2D slika nivoa snage signala dimenzija 256×256 piksela. Tako formirane 2D slike nivoa snage signala se pridružuju odgovarajućim slikama reljefa terena radi formiranja ulazno-izlaznih parova. Nakon formiranja modela, 2D slika sa nivoom snage signala dobijena predikcijom se vraća u originalan opseg vrednosti i kao takva predstavlja rezultat predikcije kreiranog propagacionog modela.

III. ARHITEKTURA MODELA

Za arhitekturu neuralne mreže na kojoj se model zasniva izabrana je U-Net mreža. U-Net neuralna mreža predstavlja poseban tip konvolucione neuralne mreže čija je prvobitna namena bila semantička segmentacija slika korišćenih u biomedicinskim istraživanjima. Klasične konvolucione mreže se najčešće koriste za probleme klasifikacije. Takođe, primena konvolucionih neuralnih mreža može biti i u domenu regresije, a primeri takve upotrebe se mogu pronaći i u radovima koji se odnose na predikcione modele [5], [6], [7]. Za razliku od klasičnih konvolucionih mreža, primena U-Net mreže pored klasifikacije omogućuje i lokalizaciju na taj način što se klasa dodeljuje svakom pikselu na slici. Broj kanala u izlaznoj slici odgovara broju klasa koje je potrebno prepoznati. Time je ostvarena arhitektura koja omogućuje dobijanje slike kao izlaznog podatka iz mreže na osnovu slike kao ulaznog podatka. Kako cilj predikcionog modela u ovom radu nije klasifikacija pojedinačnih piksela, već predikcija nivoa snage signala u svakoj tački predstavljenoj pikselom, bilo je potrebno prilagoditi arhitekturu U-Net mreže problemu regresije. Potrebne izmene su podrazumevale da regresioni sloj zameni *softmax* sloj i sloj za klasifikaciju piksela, koji su tipični u arhitekturi U-Net mreže kada se ona koristi za potrebe semantičke segmentacije. Izmena u odnosu na tipičnu

arhitekturu U-Net mreže je i postavljanje broja kanala u poslednjem konvolucionom sloju na jedan [14] jer je cilj dobijanje slike sa jednim kanalom (*grayscale image*), gde vrednost svakog piksela odgovara nivou snage signala za oblast od interesa predstavljenu tim pikselom.

Arhitektura U-Net mreže je kreirana u okviru programskog paketa *Matlab*, konkretno, *Deep Learning Toolbox-a* i *Deep Network Designer-a*. Mreža se sastoji iz dva dela, prvi tzv. *contracting path* i drugi, tzv. *expansive path* [9] koji se mogu označiti i kao *encoder* i *decoder* podmreže [14]. Prvi deo se sastoji od po dva uzastopna konvolucionih sloja praćena ReLU (*Rectified Linear Unit*) slojem, nakon čega sledi *maxpooling* sloj koji redukuje dimenzije slike. ReLU sloj je izabran za sloj aktivacione funkcije u arhitekturi kreirane mreže jer su performanse kreiranog modela bile znatno bolje prilikom njegove upotrebe, nego što je to bilo u slučaju korišćenja neke druge aktivacione funkcije. Sa svakim blokom pomenutih slojeva u *encoder* delu mreže se redukuju dimenzije ulazne slike i duplira broj kanala. Broj ponavljanja bloka slojeva u *encoder* delu mreže, odnosno, broj redukovanih dimenzija ulazne slike, određen je dubinom mreže. Suprotno prvom delu mreže koji redukuje dimenzije ulazne slike, drugi deo mreže vraća dimenzije slike pomoću sloja koji vrši transponovanu konvoluciju. Nakon svakog sloja koji vrši transponovanu konvoluciju praćenog ReLU slojem, slede po dva uzastopna sloja konvolucije praćena ReLU slojem. Broj koraka u *decoder* delu mreže jednak je broju koraka u *encoder* delu mreže. Između *encoder* i *decoder* dela mreže postoji još nekoliko slojeva koji pored sloja konvolucije, ReLU i *maxpooling* sloja sadrže i *dropout* sloj koji se koristi u cilju sprečavanja *overfitting-a*, odnosno pretreniravanja mreže. Konkatenacija delova proračuna iz *encoder* dela mreže na odgovarajuće delove proračuna u *decoder* delu mreže, tzv. *skipconnections*, je omogućena pomoću *deepConcatenation* sloja u okviru pomenutog *toolbox-a*. Poslednji sloj u mreži je regresioni sloj koji računa *half-mean-squared-error-loss* za probleme regresije između proračunatih vrednosti, odnosno, vrednosti nivoa snage signala dobijenih primenom teorijskog modela, i rezultata predikcije. Specifični parametri arhitekture mreže korišćene za formiranje propagacionog modela predstavljeni su u Tabeli 2.

TABELA II. PARAMETRI ARHITEKTURE MREŽE

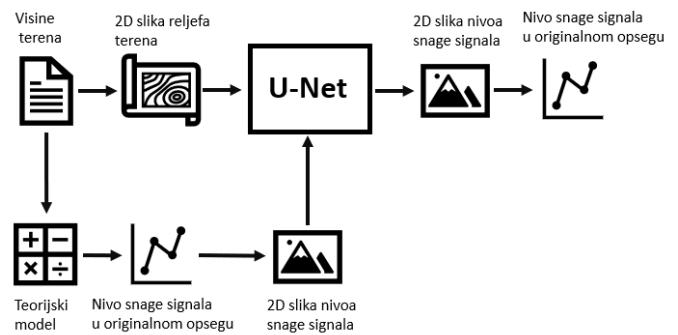
Dimenzije ulazne slike u pikselima	256×256
Dubina mreže	7
Broj izlaznih kanala za prvi blok slojeva u <i>encoder</i> delu mreže	8
Konvolucioni sloj – veličina filtera	3×3
Konvolucioni sloj – korak (stride)	[1 1]
Konvolucioni sloj – dopuna (padding)	‘same’ ^a
Maxpolling sloj - korak	[2 2]

a. Konvolucija ne menja dimenzije slike

IV. OBUČAVANJE MODELA

Predikcija nivoa snage signala odgovara nadgledanom tipu učenja (*supervised learning*) i regresiji, odnosno, predikciji kontinualnih veličina. Mreža je obučavana sa ciljem da se minimizuje kvadratni koren srednje kvadratne greške (eng. *root mean squared error*, RMSE), između vrednosti koje su dobijene primenom teorijskog modela, i koje se smatraju tačnim, i vrednosti koje su dobijene predikcijom.

Za potrebe formiranja i testiranja modela za predikciju kreiran je skup podataka sačinjen od 2858 ulazno-izlaznih parova. Ulazno-izlazni parovi su formirani na način predstavljen u drugom poglavljju. Skup podataka je podeljen na trening, validacioni i test skup podataka. Trening skup podataka čini 70% ukupnog skupa podataka (2002 ulazno-izlazna para), dok validacioni i test skup podataka čine po 15% ukupnog skupa podataka (po 428 ulazno-izlaznih parova). Mreža je obučavana nad trening skupom podataka, dok je validacioni skup služio da spreči problem *overfitting-a*, odnosno, pretreniravanja mreže. Naime, tokom obučavanja mreže, nakon svake pedesete iteracije, računata je greška i nad validacionim skupom podataka. Onda kada bi ta greška šesti put zaredom nastavila da raste, obučavanje mreže bi bilo zaustavljeno. Time je sprečeno da se mreža previše prilagodi skupu podataka korišćenih za obučavanje, što bi dovelo do loših generalizacionih osobina modela i loših rezultata nad novim podacima. Test skup podataka ni na koji način nije učestvovao u formiranju modela i korišćen je isključivo za potrebe testiranja formiranog modela u cilju određivanja njegove tačnosti. U procesu obučavanja mreže je korišćen Adam optimizacioni algoritam [15], a za stopu učenja (*learning rate*) je izabrana vrednost 0.001. Obučavanje mreže je završeno u 23 epohe, gde jedna epoha predstavlja prolaz kroz ceo trening skup podataka [14]. Svaka epoha se sastoji iz određenog broja iteracija. Broj iteracija u jednoj epohi je određen *mini-batch size* vrednošću koja definiše količinu podataka nakon koje se vrši ažuriranje težinskih koeficijenata u cilju minimizacije funkcije greške i predstavlja jedan od hiperparametara koji se podešava pre procesa obučavanja mreže. Za *mini-batch size* je izabrana vrednost 10. Pojednostavljeni blok dijagram predstavljenog modela je prikazan na Sl. 2.



Slika 2. Pojednostavljeni blok dijagram modela

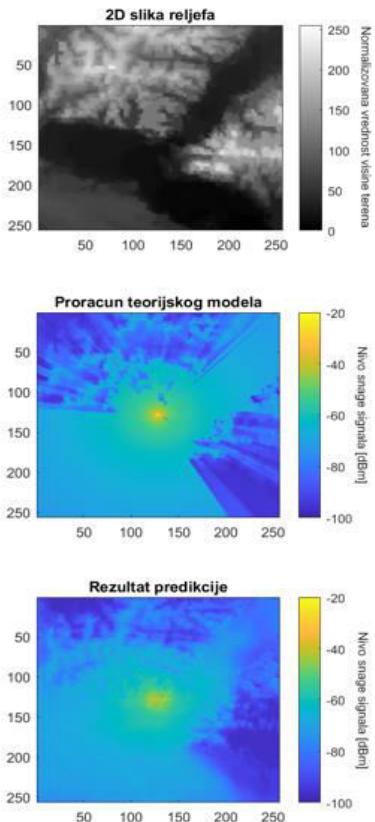
V. REZULTATI

Procena tačnosti kreiranog modela je vršena nad podacima iz test skupa (428 ulazno-izlaznih parova) koji ni na koji način nisu učestvovali u procesu obučavanja mreže. Time je sprečeno dobijanje previše optimističnih rezultata koji bi bili posledica testiranja nad podacima koje je mreža već koristila u procesu obučavanja. Statistički parametri koji su korišćeni u cilju procene tačnosti kreiranog modela su RMSE, standardna devijacija (eng. *standard deviation*, STD) i srednja vrednost (eng. *mean*). Svaki piksel u slici nivoa snage signala u realnosti predstavlja srednju vrednost nivoa snage signala na teritoriji kojoj odgovaraju dimenzije $50 \text{ m} \times 50 \text{ m}$. Za svaki piksel je računata greška koja postoji između tačne, odnosno vrednosti dobijene teorijskim modelom, i vrednosti dobijene predikcijom. Na osnovu dobijenih grešaka za svaku sliku računati statistički parametri. Vrednosti statističkih parametara predstavljenih u Tabeli 3 dobijene su usrednjavanjem statističkih parametara za svaku od slika dobijenih predikcijom na osnovu test skupa podataka.

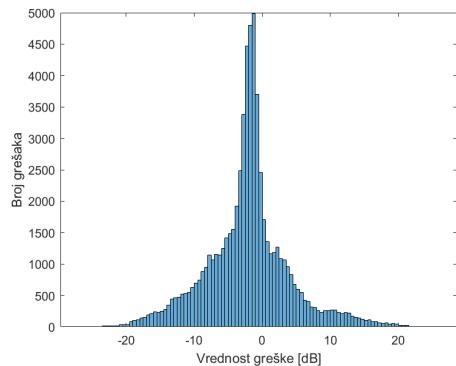
TABELA III. VREDNOSTI STATISTIČKIH PARAMETARA NAD TEST SKUPOM PODATAKA

RMSE [dB]	7.3652
STD [dB]	6.2261
MEAN [dB]	0.8332

Vizuelni prikaz tačne vrednosti i vrednosti dobijene predikcijom, kao i prikaz reljefa proizvoljno izabrane lokacije iz test skupa podataka za koju je predikcija vršena, predstavljeni su na Sl. 3. U Tabeli 4 su date i vrednosti statističkih parametara za specifičnu lokaciju predstavljenu na Sl. 3. Na Sl. 4 je predstavljen histogram grešaka za predikciju na datoj lokaciji.



Slika 3. Vizuelni prikaz predikcije za predstavljeni teren



Slika 4. Histogram grešaka za proizvoljno izabranu lokaciju

TABELA IV. VREDNOSTI STATISTIČKIH PARAMETARA NAD PROIZVOLJINOM TEST LOKACIJOM

RMSE [dB]	6.4847
STD [dB]	6.1421
MEAN [dB]	-2.0801

VI. ZAKLJUČAK

Postoji više načina na koje se model predstavljen u ovom radu može unaprediti. Pored optimizacije koja se odnosi na izbor arhitekture i parametara korišćenih u procesu obučavanja mreže, neophodno je i obogatiti ulaz u model dodatnim podacima, što mogu biti i informacije o načinu korišćenja zemljišta na teritoriji od interesa. Jedan od glavnih načina za unapređenje predstavljenog modela jeste korišćenje realnih vrednosti nivoa snage signala dobijenih terenskim merenjem kao targeta, umesto rezultata proračuna zasnovanih na teorijskom modelu. Time bi se dobio model koji bi davao realističniju predikciju čiji bi rezultati imali upotrebnu vrednost. Stoga će cilj daljeg istraživanja autora biti kreiranje propagacionog modela koji se zasniva na principu predstavljenom u ovom radu, ali će akcenat biti stavlen na veći stepen optimizacije arhitekture i hiper-parametara za treniranje s jedne strane, kao i razmatranje potpunije baze podataka i zasnivanje modela na terenskim merenjima s druge strane.

LITERATURA

- [1] A. Marey, M. Bal, H. F. Ates and B. K. Gunturk, "PL-GAN: Path Loss Prediction Using Generative Adversarial Networks," in *IEEE Access*, vol. 10, pp. 90474-90480, 2022, doi: 10.1109/ACCESS.2022.3201643.
- [2] 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.
- [3] 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.
- [4] S. Sotiroudis, 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.

- [5] Sotirios P. Sotiroudis, 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.
- [6] 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.
- [7] 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.
- [8] 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.
- [9] 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.
- [10] R. Levie, Ç. Yapar, G. Kutyniok and G. Caire, "RadioUNet: Fast Radio Map Estimation With Convolutional Neural Networks," in *IEEE Transactions on Wireless Communications*, vol. 20, no. 6, pp. 4001-4015, 2021.
- [11] ITU-R. P 525-4 Calculation of free-space attenuation
- [12] ITU-R P.526-15: Propagation by diffraction
- [13] 3GPP TS 36.521-1 V12.6.0 (2015-06)
- [14] The MathWorks, Inc. Deep Learning Toolbox: User's Guide (R2022b)`
- [15] Kingma, Diederik & Ba, Jimmy. (2014). Adam: A Method for Stochastic Optimization. *International Conference on Learning Representations*.

ABSTRACT

The paper presents a model for predicting the signal strength level based on the application of deep learning, specifically on the U-Net network. The proposed model enables the prediction of the signal strength level in macrocells based on the terrain image as input data. The result is a map with the signal strength level for a given macrocell. The prediction for 428 test macrocell locations is provided in a few seconds with an accuracy of 7.3652 dB, when the RMSE (root mean squared error) averaged over all locations is considered as a statistical parameter.

PREDICTION OF SIGNAL STRENGTH LEVELS IN MOBILE RADIO NETWORKS USING U-NET NETWORK

Jelena Mladenovic, Aleksandar Neskovic, Natasa Neskovic