



PREPOZNAVANJE KARAKTERISTIKA MODULACIJE PRIMENOM TEHNIKA DUBOKOG UČENJA

AUTOMATIC MODULATION RECOGNITION USING DEEP LEARNING TECHNIQUES

Milica Jankov, *Fakultet tehničkih nauka, Novi Sad*

Oblast – ELEKTROTEHNIČKO I RAČUNARSKO INŽENJERSTVO

Kratak sadržaj – *U ovom radu analiziraju se performanse dva modela mašinskog učenja u prepoznavanju modulacionih šema: konvolucionala (CNN) i LSTM neuronska mreža. Koristeći sintetički skup podataka RadioML2016.10a, modeli su obučavani i testirani na 11 različitih tipova modulacije u opsegu SNR od -20 dB do +20 dB. Rezultati pokazuju da obe modela ostvaruju visoku tačnost, s tim da LSTM mreža pokazuje blagu prednost u performansama prilikom klasifikacije modulacija pri višim SNR vrednostima. Ova analiza doprinosi razvoju naprednih tehnika prepoznavanja modulacije koje mogu poboljšati efikasnost kognitivnog radija u složenim spektralnim okruženjima.*

Ključne reči: Automatsko prepoznavanje modulacije, Kognitivni radio, Konvolucione neuronske mreže, Long Short-Term Memory, Duboko učenje

Abstract – *This paper analyzes the performance of two machine learning models in modulation scheme recognition: Convolutional Neural Network (CNN) and Long Short-Term Memory (LSTM) network. Using the synthetic RadioML2016.10a dataset, the models were trained and tested on 11 different modulation types within an SNR range from -20 dB to +20 dB. The results show that both models achieve high accuracy, with the LSTM network demonstrating slightly better performance in modulation classification at higher SNR values. This analysis contributes to the development of advanced modulation recognition techniques that can enhance the efficiency of cognitive radio in complex spectral environments.*

Keywords: Automatic Modulation Recognition, Cognitive Radio, Convolutional Neural Networks, Long Short-Term Memory, Deep Learning

1. UVOD

Globalni porast umreženih uređaja stvara veliku potražnju za radio-frekvencijskim spektrom, što čini tradicionalni pristup dodeljivanja spektra, gde su fiksni frekvencijski opsezi ekskluzivno dodeljeni licenciranim primarnim korisnicima (*Primary Users*, PU), neodrživim.

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio doc. dr Milan Narandžić.

Tehnologija kognitivnog radija rešava problem neiskorišćenog spektra, tako što omogućava nelicenciranim sekundarnim korisnicima (*Secondary Users*, SU) da koriste neaktivne kanale primarnih korisnika bez izazivanja smetnji. Sekundarni korisnici pri tome moraju primeniti robustne tehnike detekcije spektra (*Spectrum Sensing*, SS) kako bi precizno detektovali prisustvo ili odsustvo primarnih korisnika u kanalima.

Automatsko prepoznavanje modulacije (*Automatic Modulation Recognition*, AMR) predstavlja jedan od ključnih segmenata razvoja kognitivnog radija (*Cognitive Radio*, CR), koji omogućuje adaptivnu demodulaciju detektovanih signala [1]. Pretpostavka o poznavanju tipa modulacije omogućava sekundarnim korisnicima da preciznije razlikuju različite primarne korisnike, čime dobijaju detaljniji uvid o spektru, što im pomaže u donošenju informisanih odluka o tome kada i gde treba da obave prenos. Rezultati prepoznavanja modulacije mogu dodatno doprineti identifikaciji karakteristika interferirajućih signala, omogućavajući primenu ciljanih tehnika za suzbijanje interferencije. U cilju postizanja što tačnijih rezultata, ovaj rad se fokusira na analizu performansi različitih modela namenjenih rešavanju problema klasifikacije modulacionih šema.

2. PREPOZNAVANJE MODULACIJE

Osnovni cilj ispitivanja zauzetosti spektra (*spectrum sensing*) je da omogući saznanja o prisutnim predajnicima kako bi se izbegla radio interferencija i optimizovala raspodela spektra. To podrazumeva identifikaciju emitovanih radio signala i drugih potencijalnih smetnji, pri čemu sve emisije poseduju određene specifičnosti. U tom kontekstu, prepoznavanje modulacije ima za cilj klasifikaciju tipa modulacije na osnovu primljenog radio signala, što predstavlja važan korak ka identifikaciji komunikacionih šema i predajnika u okolini.

2.1. Potreba za primenom mašinskog učenja

Prepoznavanje modulacije može se tretirati kao problem klasifikacije u više klase, gde se odluka donosi za jednu od N klase. Postojeće metode tog tipa mogu se podeliti u dve grupe: metode zasnovane na verodostojnosti (*likelihood-based*) i metode zasnovane na obeležjima (*feature-based*) [2]. Kao alternativa navedenim pristupima, nedavno su se pojavile metode zasnovane na dubokom učenju, koje direktno uče iz primljenih signala. Cilj je ispitati da li predložene tehnike pružaju veću fleksibilnost u učenju ključnih karakteristika u poređenju s tradicionalnim,

analitičkim pristupima koji se oslanjaju na ljudski ekspertizu. Za poređenje ostvarenih performansi biće korišćena tačnost klasifikacije.

2.2. Formulacija problema

Ulazni podatak predstavlja primljeni signal u obliku kompleksnog vremenskog niza u osnovnom opsegu. Uzorkovanje komponenti radio signala u fazi i kvadraturi obavlja se u diskretnim vremenskim intervalima, što rezultuje kompleksnim vektorom veličine $1 \times N$.

Takav zapis predstavljen je u jednačini (1),

$$r(t) = s(t) \cdot c + n(t), \quad (1)$$

gde $s(t)$ označava vremenski niz signala, predstavljen u kontinualnom ili diskretnom vremenu. Ovaj signal se sastoji od niza bita modulisanih u sinusoidu sa promenljivim parametrima koji uključuju frekvenciju, fazu, amplitudu, putanje ili neku kombinaciju ovih faktora. Konstanta c označava slabljenje duž putanje (*path loss*) ili konstantno pojačanje signala, dok $n(t)$ predstavlja aditivni beli Gausov proces koji označava termički šum.

Osnovni cilj bilo kog klasifikatora modulacije je da izrazi verovatnoću

$$P(s(t) \in N_i | r(t)), \quad (2)$$

gde je $r(t)$ jedini referentni signal, a N_i predstavlja i -tu klasu. Primljeni signal $r(t)$ se obično predstavlja u *IQ* formatu zbog svoje fleksibilnosti i jednostavnosti za primenu matematičkih operacija i dizajn hardvera. Komponente signala u fazi i kvadraturi izražene su kao:

$$I = A \cos(\varphi), \quad (3)$$

i

$$Q = A \sin(\varphi), \quad (4)$$

gde A i φ predstavljaju trenutnu amplitudu i fazu primljenog signala $r(t)$.

Za problem klasifikacije modulacije, *IQ* komponente uzorkovanog signala predstavljaju obeležja od interesa. Pored formatiranja ulaznih podataka u vidu *IQ* uzoraka (pravougaone koordinate), moguće je koristiti predstavljanje ulaznih podataka kroz amplitudu i fazu (polarne koordinate).

3. RAZMATRANE METODE ZA AUTOMATSKU DETEKCIJU KARAKTERISTIKA MODULACIJE

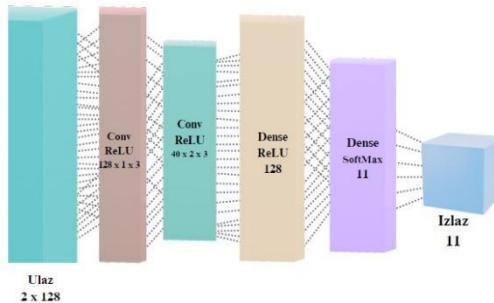
3.1. Konvolucionna neuronska mreža (CNN)

U sistemima radio komunikacija, često razmatrana klasa prijemnika uključuje korišćenje prilagođenog filtra. Na prijemnoj strani, za svaki specifično dizajnirani filter, uparen sa odgovarajućim prenetim simbolom, vrši se konvolucija sa dolaznim vremenskim signalom. Motivacija za primenu konvolucionih neuronskih mreža (*Convolutional Neural Network*, CNN) u ovom kontekstu leži u očekivanju da će CNN moći automatski da oblikuju prilagodene filtre za različite vremenske karakteristike signala, dok istovremeno optimizuju performanse pri različitim nivoima odnosa SNR. Cilj je iskoristiti invarijantnost konvolucione neuronske mreže na pomeranje, kako bi se kreirali prilagođeni filtri sposobni da automatski izdvoje ključne karakteristike prenetih simbola,

bez dodatnih mrežnih informacija ili estimacije osnovnog talasnog oblika. Ovakav pristup bi mogao da obezbedi robustnu osnovu za rešavanje problema klasifikacije modulacija.

Prvi metod za učenje obeležja, konvolucionna neuronska mreža (CNN), koristi prozorirani ulaz originalnog vremenskog niza radio signala $r(t)$. Ovaj kompleksni signal tretira se kao dvodimenzionalni realni ulaz, gde se $r(t)$ predstavlja kao $2 \times N$ vektor u kompaktnoj 2D konvolucionoj mreži. Dimenziju veličine 2 formiraju ortogonalno sinhronizovani uzorci u fazi i kvadraturi (*IQ*).

CNN model koji se koristi u ovoj arhitekturi (slika 1) sastoji se od četiri sloja — dva konvolucionna sloja i dva potpuno povezana - gusta (*dense*) sloja. Nakon konvolucionih slojeva, izlaz se spaja sa prvim potpuno povezanim - gustim (*dense*) slojem, koji integriše informacije iz prethodnih slojeva i zatim ih prosleđuje ka završnom klasifikacionom sloju. Završni sloj je drugi potpuno povezani - gasti (*dense*) sloj koji sadrži n neurona, gde je n broj klasa u klasifikacionom zadatku (u razmatranom slučaju, $n = 11$). Obuka se sprovodi koristeći kategoričku unakrsnu entropiju (*categorical cross-entropy*) kao funkciju gubitka, dok je za optimizaciju odabran Adam (*Adaptive Moment Estimation*) optimizator [3].



Slika 1. Ilustracija CNN arhitekture.

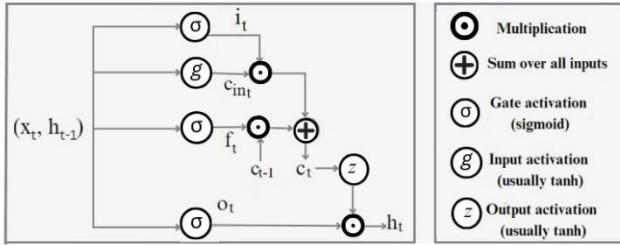
3.2. Long Short-Term Memory (LSTM)

Naredni metod za učenje obeležja koristi LSTM (*Long Short-Term Memory*) neuronske mreže. Za razliku od prethodno opisanog pristupa, ovaj model se obučava na osnovu informacija o amplitudi i fazu u vremenskom domenu, oslanjajući se na modulacione šeme iz podataka za obuku, bez potrebe za dodatnim ekspertskim obeležjima, poput cikličnih momenata višeg reda. Zahvaljujući LSTM celijama, koje su poznate po efikasnosti u učenju dugih vremenskih sekvenci, očekuje se da bi predloženi model mogao da prepozna dugoročne zavisnosti u podacima, bez potrebe za eksplisitnim izdvajanjem obeležja.

LSTM model koji se opisuje u nastavku predstavlja poseban tip Rekurentnih neuronskih mreža (*Recurrent Neural Networks*, RNN), često korišćenih za izdvajanje obeležja iz vremenskih nizova podataka. Blok dijagram osnovne verzije LSTM celije prikazan je na slici 2.

Osnovu funkcionisanja LSTM celije čini njeno interno stanje ili memorija c_t zajedno sa tri ulaza: ulaz za unos podataka (input gate, i_t), mehanizam za kontrolu pamćenja (forget gate, f_t) i krajnji izlaz (output gate, o_t). Na osnovu prethodnog stanja i ulaznih podataka, celije mogu naučiti

ulazne težine za određeni problem. Ovaj mehanizam koji je zasnovan na različitim ulazima, omogućava LSTM celijama da skladište informacije tokom dužeg vremenskog perioda, što podstiče učenje trajnih obeležja.



Slika 2. LSTM ćelija korišćena u skrivenim slojevima modela.

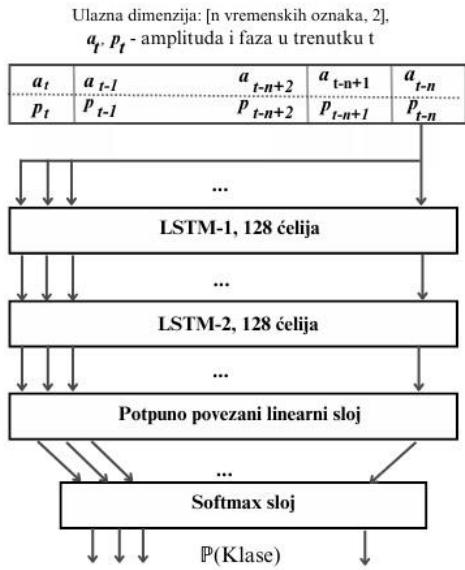
Za klasifikaciju kompleksnih signala koristi se LSTM mreža sa dva sloja, kao što je prikazano na slici 3. U svakom trenutku, t , vrednosti, amplituda i faza modulisanog signala, unose se u LSTM ćelije u obliku dvodimenzionalnog vektora. Vrednosti amplituda su normalizovane primenom L_2 norme, dok je faza, izražena u radijanima, skalirana na opseg od -1 do 1. Prva dva sloja modela sadrže po 128 LSTM ćelija. Konačni izlaz iz drugog LSTM sloja, vektor dimenzije 128, koristi se kao ulaz za završni gusti sloj (*dense layer*). Ovaj sloj je gusti Softmax sloj (*dense Softmax layer*) koji mapira naučena obeležja na jednu od 11 klasa, koje predstavljaju različite šeme modulacije. Aktivaciona funkcija koja se koristi u ovom sloju jeste Softmax, koja omogućava modelu da predviđa verovatnoće za svaku klasu, čime daje procenu klase kojoj signal pripada.

4. REZULTATI

Skup podataka koji je sintetički generisan korišćenjem GNU Radio [4], pod nazivom *RadioML2016.10a*, koristi se u ovom radu za obuku i procenu performansi klasifikatora. Ključna metrika uspešnosti bila je postignuta tačnost na test skupu. U postupku evaluacije, podaci su podeljeni na skup za obuku (60%) i skupove za validaciju i testiranje (po 20% svaki). Obuka je sprovedena na približno 33 miliona kompleksnih uzoraka, podeljenih u 11 različitih modulacionih šema, koje u nastavku označavamo standardnim akronimima: 8PSK, AM-DSB, AM-SSB, BPSK, CPFSK, GFSK, 4PAM, 16QAM, QPSK i WBFM. Raspoloživi uzorci su grupisani u segmente od po 128 instanci. Skupovi za validaciju i testiranje sadrže približno 11 miliona kompleksnih uzoraka, koji su ravnomerno raspoređeni prema različitim vrednostima odnosa signala i šuma (SNR), u rasponu od -20 dB do +20 dB. Ovo omogućava procenu performansi klasifikatora u prisustvu različitih nivoa šuma.

4.1. CNN

Na osnovu matrice konfuzije za CNN klasifikator pri odnosu SNR od 18 dB (slika 4), moguće je primetiti nekoliko važnih aspekata. Modulacije poput CPFSK, 4-PAM, BPSK, i GFSK imaju izuzetno veliku tačnost, dostižući vrednosti bliske 100%. To znači da CNN klasifikator veoma uspešno prepoznaje ove modulacije pri visokom odnosu SNR, gde je šum minimalan, što olakšava tačno razlikovanje karakteristika signala.



Slika 3. Dvoslojni LSTM model za klasifikaciju.

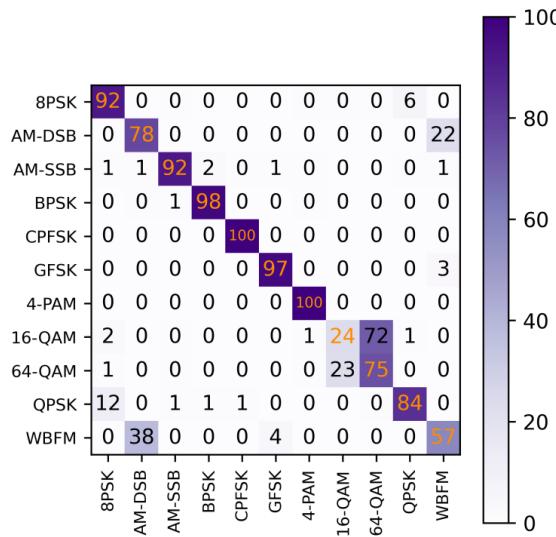
Pri razlikovanju 16-QAM i 64-QAM, CNN i dalje pokazuju određeni stepen međusobne zbnjenosti. Iako je tačnost za 64-QAM (75%) solidna, postoji značajan broj uzoraka iz 16-QAM (72%) koji su pogrešno klasifikovani kao 64-QAM, što ukazuje na to da CNN klasifikator nije sasvim uspešan u razdvajaju ova dva tipa modulacija čak ni pri visokom odnosu SNR. Potencijalni razlog za to jesu sličnosti u njihovim kvadraturnim amplitudskim osobinama, gde konstelacija nižeg reda predstavlja podskup tačaka iz konstelacije višeg reda.

Iako QPSK pokazuje solidnu tačnost (84%), postoji određeni nivo zbnjenosti sa 8PSK (12% uzoraka QPSK pogrešno klasifikovano kao 8PSK). Ovim se primećuje da fazne modulacije sa višestrukim faznim stanjima predstavljaju izazov za CNN, iako pri višim odnosima SNR klasifikacija postaje preciznija. WBFM pokazuje malu tačnost (57%) i čestu pogrešnu klasifikaciju kao AM-DSB, gde je 38% uzoraka WBFM signala pogrešno klasifikovano kao AM-DSB. U skladu sa prethodnim zapažanjima, moguće je zaključiti da CNN klasifikator ima problem sa razlikovanjem ove dve modulacije, verovatno zbog sličnih karakteristika njihovih osobina.

Dakle, pri odnosu SNR od 18 dB, CNN klasifikator pokazuje vrlo visoku tačnost (81.54%) za većinu modulacija, posebno za CPFSK, BPSK, i GFSK. Međutim, i dalje postoje problemi sa međusobnim razlikovanjem 16-QAM i 64-QAM, kao i značajnim neraspoznavanjem između WBFM i AM-DSB.

4.2. LSTM

Na osnovu prikazane matrice konfuzije za LSTM klasifikator pri SNR od 18 dB (slika 5), sa ukupnom tačnošću od 85.05%, moguće je uočiti nekoliko ključnih aspekata. Velika tačnost za određene modulacije 8PSK, AM-DSB, BPSK, CPFSK, GFSK, 4-PAM i QPSK (iznad 96%), ukazuje na to da LSTM model izuzetno dobro klasificuje ove modulacije pri 18 dB. Na primer, za CPFSK, GFSK, i 4-PAM, tačnost je 100%, što znači da nijedan uzorak ovih modulacija nije pogrešno klasifikovan.



Slika 4. Matrica konfuzije pri odnosu SNR od 18 dB za CNN klasifikator.

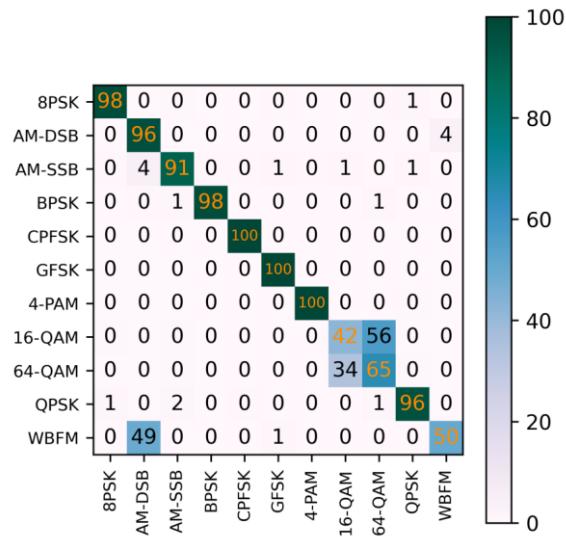
Postoji nekoliko manjih grešaka kod AM-SSB, ali generalno ova modulacija pokazuje visok nivo tačnosti (91%), što znači da je model uspešan u klasifikaciji ove modulacije pri većim vrednostima SNR. Model postiže vrlo dobre rezultate za većinu modulacija, ali ima određene poteškoće sa razlikovanjem sličnih kvadraturnih modulacija (16-QAM i 64-QAM) i sa WBFM modulacijom.

Slično kao u prethodnom eksperimentu, problemi prilikom klasifikovanja WBFM modulacije potvrđuju da ona predstavlja izazov za klasifikaciju čak i pri visokom odnosu SNR. Ostvarena tačnost iznosi 50%, a 49% slučajeva je greškom klasifikovano kao AM-DSB. Ova matrica konfuzije ukazuje na najznačajnije probleme u klasifikaciji, i može biti smernica za dalja poboljšanja modela.

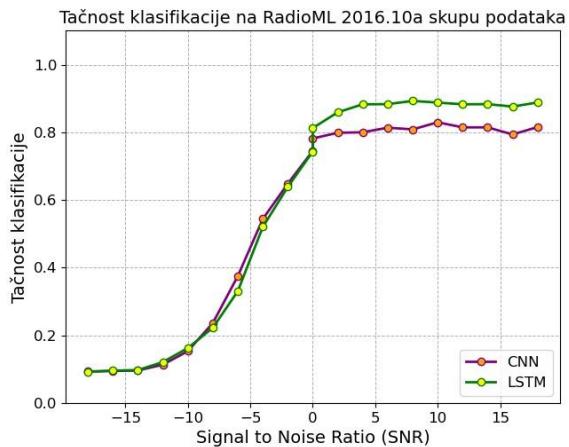
5. ZAKLJUČAK

Sprovedeni eksperimenti pokazuju da drugi analizirani model, koji se zasniva na primeni LSTM ćelija, dovodi do povećanja tačnosti od 3.51% (na test skupu) u poređenju sa tačnošću koja se postiže primenom modela zasnovanog na konvolucionim neuronskim mrežama. Prosječna tačnost klasifikacije za SNR vrednosti u rasponu od 0 dB do 18 dB, postignuta primenom CNN i LSTM modela, iznosi 55.86% i 58.87%, respektivno. Prikaz na slici 6 ističe prednost LSTM modela u odnosu na CNN model, naročito pri višim SNR vrednostima, gde njegova sposobnost izdvajanja robusnih karakteristika dovodi do superiornih performansi.

Međutim, s obzirom da oba modela pokazuju slične slabosti pri razlikovanju modulacija sa kvadraturnim amplitudskim osobinama i WBFM, to ukazuje na potrebu za daljom optimizacijom, predobradom signala ili primenom složenijih modela kako bi se dodatno unapredila tačnost klasifikacije.



Slika 5. Matrica konfuzije pri odnosu SNR od 18 dB za CNN klasifikator.



Slika 6. Prosječna tačnost klasifikacije za dva ispitivana modela.

6. LITERATURA

- [1] Y. Wang, M. Liu, J. Yang, G. Gui, "Data-Driven Deep Learning for Automatic Modulation Recognition in Cognitive Radios", IEEE Transactions on Vehicular Technology, vol. 68, no. 4, pp. 4074-4077, April 2019. Dostupno na: <https://ieeexplore.ieee.org/document/8645696>.
- [2] Z. Ke, H. Vikalo, "Real-Time Radio Technology and Modulation Classification via an LSTM Auto-Encoder", Novembar 2020, Dostupno na: <https://arxiv.org/abs/2011.08295>.
- [3] D. P. Kingma, J. Ba, "Adam: A Method for Stochastic Optimization", Januar 2017. Dostupno na: <https://arxiv.org/abs/1412.6980>
- [4] J. L. Ziegler, R. T. Arn, W. Chambers, "Modulation recognition with GNU radio, keras, and HackRF", Mart 2017. Dostupno na: <https://ieeexplore.ieee.org/document/7920747>.

Kratka biografija:

Milica Jankov rođena je u Zrenjaninu 2000. god. Master rad na Fakultetu tehničkih nauka iz oblasti Elektrotehnike i računarstva – Telekomunikacioni sistemi odbranila je 2024.god.

Kontakt: milicajankov@uns.ac.rs