

# Primena veštačkih neuralnih mreža za automatsko prepoznavanje digitalne modulacije u softverski definisanom i kognitivnom radiju

Marko Roganović, Aleksandar Nešković, Nataša Nešković

**Sadržaj** — Rad prikazuje jednu metodu za automatsko prepoznavanje digitalne modulacije signala, što može biti od posebnog značaja za softverski definisani radio, kao i kognitivni radio. Pošto su razmotrene neke od, u literaturi često korišćenih, metoda za izdvajanje obeležja iz signala koji kasnije omogućavaju klasifikaciju istih pomoću neuralnih mreža, predložena su nova obeležja, dat je predlog neuralne mreže za klasifikaciju i prikazani su rezultati simulacije koja razvaja 7 tipova digitalne modulacije pri odnosu signal/šum od 0, 5, 10, 20 i 50dB.

**Ključne reči** — automatsko prepoznavanje modulacije, izdvajanje obeležja, MLP, softverski definisani radio.

## I. UVOD

**A**UTOMATSKO prepoznavanje modulacije jedna je od oblasti koja već duže vreme privlači pažnju. Prve primene i interesovanje za nju bili su u oblasti vojnih komunikacija, ali sa razvojem softverski definisanog radija i sa premeštanjem funkcija radio sistema sve više iz domena hardvera, u domen softvera, probudila su se nova interesovanja za ovu oblast. Ona je posebno interesantna imajući u vidu ubrzani razvoj tehnologije tzv. kognitivnog radija, kao radija kome je mogućnost posedovanja svesti o okolini u kojoj se nalazi jedna od glavnih karakteristika. Mogućnost da samostalno prepozna tip kojim je primljeni signal modulisani i da na osnovu toga omogući odgovarajuću softversku demodulaciju, daje radio sistemima veliku fleksibilnost.

Postoji opsežna literatura u kojoj se autori bave ovom problematikom. Problem automatskog prepoznavanja modulacije se u principu može podeliti na dva podproblema: problem izdvajanja karakterističnih veličina iz signala koje bi omogućile klasifikaciju (u daljem tekstu obeležje) i sam problem klasifikacije. U radovima [1]-[4] i [6] problemu klasifikacije pristupano je upotrebom neuralnih mreža. Izdvajanje obeležja može se ostvariti statističkom obradom veličina poput trenutne amplitute, faze i frekvencije analitičkog signala kao u [1], korišćenjem osobina vremensko-frekvensijske raspodele

M. Roganović, Institut Mihajlo Pupin, Volgina 15, 11050 Beograd, Srbija; (e-mail: marko.roganovic@automatika.imp.bg.ac.yu).

A. Nešković, Elektrotehnički fakultet u Beogradu, Bulevar kralja Aleksandra 73, 11120 Beograd, Srbija; (e-mail: neshko@etf.bg.ac.yu).

N. Nešković, Elektrotehnički fakultet u Beogradu, Bulevar kralja Aleksandra 73, 11120 Beograd, Srbija; (e-mail: natasha@etf.bg.ac.yu).

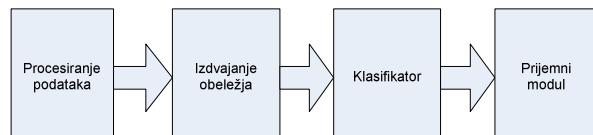
kao u [4] ili sl. U [5] dat je jedan opšti pregled statističkih metoda za prepoznavanje modulacija. U ovom radu prikazana je jedna modifikacija u izboru obeležja u odnosu na onu prikazanu u [1], kao i predložena arhitektura neuralne mreže za klasifikaciju na osnovu te modifikacije, te su izloženi rezultati dobijeni na osnovu izvršene simulacije.

Organizacija rada je sledeća: pošto je u II poglavlju data postavka problema, III poglavlje razmatra metodu obrade primljenog signala u smislu izdvajanja obeležja i njihovog odabira za klasifikaciju. IV poglavlje predstavlja arhitekturu neuralne mreže koja je korišćena u simulaciji, a čiji su rezultati izloženi u poglavlju V.

## II. POSTAVKA PROBLEMA

Problem koji se u ovom radu rešava je sledeći: na mestu predajnika generisan je signal modulisani nekom od sledećih vrsta modulacija: 2PSK, 4PSK, 16QAM, 64QAM, 2FSK, 4FSK i 4ASK. Ovako modulisani signal prolazi kroz kanal sa belim aditivnim Gausovim šumom (AWGN kanal) i to takvim da je odnos signal/šum od 0dB do 50dB na ulazu u prijemnik. U okviru automatskog prepoznavanja modulacije treba na mestu prijema, odgovarajućom obradom vremenskih odbiraka signala nepoznate modulacije, utvrditi koja je modulacija u pitanju, i time omogućiti odgovarajuću fleksibilnu demodulaciju.

Metoda za automatsku klasifikaciju modulacija predložena u ovom radu ilustrovana je kroz blok-šemu prikazanu na slici 1.



Sl. 1. Blok šema automatske klasifikacije modulacija

Pod procesiranjem podataka u prvom bloku na slici 1 podrazumeva se digitalna obrada vremenskih odbiraka signala koja će omogućiti dobijanje odgovarajućih obeležja. U sledećem bloku izdvajaju se obeležja koja na najbolji način mogu da ostvare klasifikaciju u okviru bloka sa neuralnom mrežom, koji pak daje konačan odgovor prijemnom modulu u kome se nalazi prijemnik koji podešava parametre u skladu sa rezultatima klasifikacije.

### III. PROCESIRANJE PODATAKA

#### A. Izdvajanje obeležja

Jedan od najčešćih skupova obeležja koji se u literaturi mogu sresti baziran je na vrednostima koje se mogu dobiti iz analitičkog signala: trenutna amplituda, faza i frekvencija. Analitički signal nekog signala dobija se tako što se saberi taj signal u vremenskom domenu i njegova Hilbertova transformacija pomnožena imaginarnom jedinicom, kao što je objašnjeno u [7]. Na osnovu ovog analitičkog signala autor u [5], kao i autori u [1] za odgovarajuće obeležje predlaže maksimalnu vrednost spektralne gustine snage normalizovane, centrirane trenutne amplitudu, koja je data izrazom :

$$\gamma_{\max} = \max |DFT(a_{cn}(i))|^2 / N_s , \quad (1)$$

gde je  $a_{cn}(i)$  normalizovana trenutna amplituda,  $N_s$  odgovarajući broj odbiraka, a  $i$  uzima vrednosti od 1 do  $N_s$ .

Sledeće obeležje predloženo u [1] koje je od interesa je standardna devijacija direktnе vrednosti centrirane nelinearne komponente trenutne faze  $\phi_{NL}(i)$ , data izrazom.

$$\sigma_{dp} = \sqrt{\frac{1}{C} \left( \sum_{a_n(i) > a_t} \phi_{NL}^2(i) \right) - \left( \frac{1}{C} \sum_{a_n(i) > a_t} \phi_{NL}(i) \right)^2} , \quad (2)$$

kao i standardna devijacija apsolutne vrednosti normalizovane centrirane trenutne frekvencije  $f_N(i)$ .

$$\sigma_{af} = \sqrt{\frac{1}{C} \left( \sum_{a_n(i) > a_t} f_N^2(i) \right) - \left( \frac{1}{C} \sum_{a_n(i) > a_t} |f_N(i)| \right)^2} . \quad (3)$$

U ovim izrazima uzeto je samo C onih odbiraka u obzir, za koje je vrednost trenutne amplitude bila veća od nekog praga  $a_t$  (ovde uzeto  $a_t = 1$ ) [5]. Detaljan opis formiranja ovih obeležja, kao i formiranje novih obeležja na bazi apsolutne vrednosti trenutne faze i apsolutne vrednosti trenutne amplitude dati su u [5].

Pored (1), (2) i (3), praksa pokazuje da je neophodno uključiti i druge statistike višeg reda, kako bi odgovarajuća klasifikacija bila zadovoljavajuća. Zbog toga se u izbor obeležja u [1] uključuju i kumulantni drugog, trećeg i četvrtog reda, nultog pomeraja, dati u okviru izraza (4), (5) i (6), respektivno.

$$C_{X_1, X_2} = \langle X_1, X_2 \rangle = \frac{1}{N} \sum_{n=1}^N x_1^n x_2^n \quad (4)$$

$$C_{X_1, X_2, X_3} = \langle X_1, X_2, X_3 \rangle = \frac{1}{N} \sum_{n=1}^N x_1^n x_2^n x_3^n \quad (5)$$

$$C_{X_1, X_2, X_3, X_4} = \langle X_1, X_2, X_3, X_4 \rangle - \langle X_1, X_2 \rangle \langle X_3, X_4 \rangle , \quad (6)$$

$$- \langle X_1, X_3 \rangle \langle X_2, X_4 \rangle - \langle X_1, X_4 \rangle \langle X_2, X_3 \rangle$$

gde je  $X_i$  odgovarajući vektor signala  $\{x_i^1, x_i^2, \dots, x_i^N\}$ , a simbol  $\langle \cdot \rangle$  označava matematičko očekivanje. U literaturi se kao moguća obeležja predlaže kumulantni drugog, trećeg i četvrtog reda realnog i imaginarnog dela kompleksne amplitude signala od interesa.

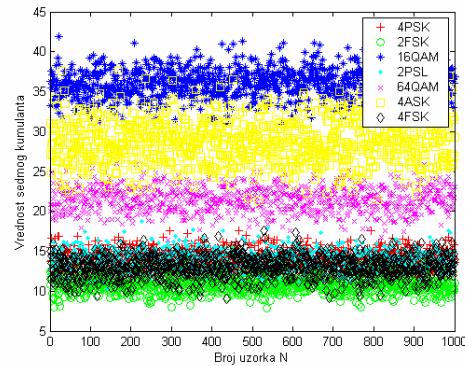
U ovom radu predloženo je da se za formiranje skupa obeležja koriste kumulantni centrirane nelinearne komponente trenutne faze i centrirane normalizovane

trenutne frekvencije. U (7) prikazani su svi kumulantni drugog, trećeg i četvrtog reda te dve veličine.

$$\begin{aligned} & C_{\phi_{NL}\phi_{NL}}, C_{\phi_{NL}f_N}, C_{f_Nf_N}, C_{\phi_{NL}\phi_{NL}\phi_{NL}}, C_{\phi_{NL}\phi_{NL}f_N}, C_{\phi_{NL}f_Nf_N}, \\ & C_{f_Nf_Nf_N}, C_{\phi_{NL}\phi_{NL}\phi_{NL}\phi_{NL}}, C_{\phi_{NL}\phi_{NL}\phi_{NL}f_N}, C_{\phi_{NL}\phi_{NL}f_Nf_N}, \\ & C_{\phi_{NL}f_Nf_Nf_N}, C_{f_Nf_Nf_Nf_N} \end{aligned} \quad (7)$$

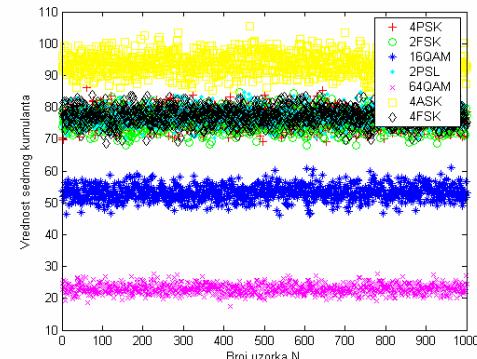
#### B. Izbor obeležja

Kako bi mogla da se izvrši dalja klasifikacija preko neuralnih mreža, neophodno je od 17 predloženih obeležja (3 iz literature date izrazima (1), (2) i (3) i 12 predloženih kumulantna u izrazu (7)) izabrati manji broj njih koji će biti ulazi u neuralnu mrežu. Odlučeno je da se u skup za klasifikaciju uključe (1), (2) i (3), kao i da se od 12 kumulantna iz (7) izaberu ona 3 koja pokazuju najbolja svojstva klasifikacije uočena tokom njihove analize.



Sl. 2. Razdvajanje modulacija koje obezbeđuje 7.

kumulant ( $C_{f_Nf_Nf_N}$ ) pri signalu od 10dB



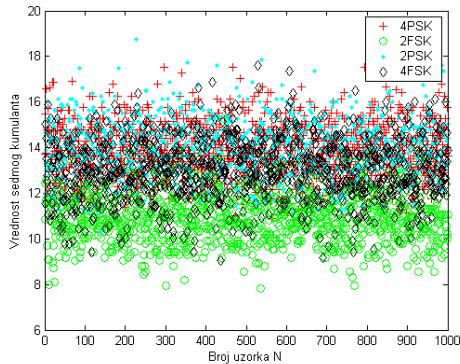
Sl. 3. Razdvajanje modulacija koje obezbeđuje 7.

kumulant ( $C_{f_Nf_Nf_N}$ ) pri signalu od 0dB

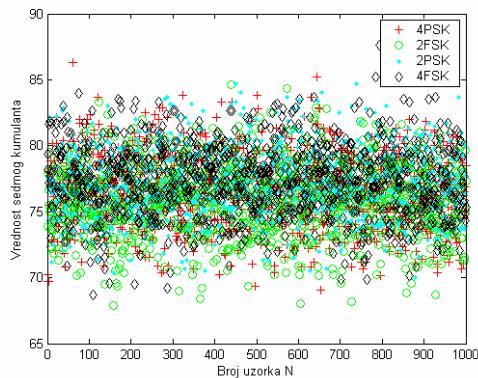
Analiza je vršena na signalima kod kojih je odnos signal/šum 10dB, da bi se ovi rezultati potom uporedili sa slučajem odnosa signal/šum od 0dB. Primer analize za 7. kumulant iz (7) ilustrovan je na slikama 2 i 3. Slika 2 ukazuje na sposobnost ovog kumulantu da izdvoji 16QAM, 64QAM, 4ASK i 2FSK modulacije pri odnosu signal/šum od 10dB. Problem, međutim, nastaje kod 2FSK modulacije na 0dB, što dobro ilustruje slika 3.

Problem nemogućnosti razdvajanja 2PSK, 4PSK i 4FSK modulacija, kao i gubljenje svojstva razdvajanja za

2FSK pri odnosu signal/šum od 0dB (za razliku od 10dB) dodatno je ilustrovana na slikama 4 i 5.



Sl. 4. Pomešane vrednosti 7. kumulanta ( $C_{f_N f_N f_N}$ ) za 4PSK, 2PSK i 4FSK pri signalu od 10dB



Sl. 5. Pomešane vrednosti 7. kumulanta ( $C_{f_N f_N f_N}$ ) za 4PSK, 2PSK i 4FSK, 2FSK pri signalu od 0dB

Slična analiza kao za 7. kumulant izvršena je za svih 12 kumulanata i zaključci tih analiza sistematizovani su u tabeli 1. U njoj je su navedene sve modulacije koje svaki od kumulanata uspešno odvaja pri odnosu signal/šum od 10dB. Na osnovu tih podataka izvršen je izbor 3 kumulanata, koji su kasnije korišćeni kao obeležja.

TABELA 1: MODULACIJE KOJE KUMULANATI RAZDVAJAJU PRI ODNOSU SIGNAL/ŠUM OD 10dB.

Kumulant	Modulacije koje razdvaja
1.	64QAM, 4PSK, 2FSK
2.	ne odvaja
3.	16QAM, 4ASK, 64QAM, 2FSK
4.	ne odvaja
5.	64QAM, 4PSK, 2FSK
6.	ne odvaja
7.	16QAM, 4ASK, 64QAM, 2FSK
8.	64QAM, 4PSK, 2FSK
9.	ne odvaja
10.	4ASK
11.	ne odvaja
12.	16QAM, 4ASK, 64QAM, 2FSK, 4FSK

Iz tabele 1 se zaključuje da najveću sposobnost razdvajanja imaju kumulanti 3, 7 i 12. Od njih su odabarni kumulanti 7 i 12, dok im je kao treće obeležje pridodat i 1. kumulant, koji ima sposobnost da razdvoji 4PSK modulaciju (što nije slučaj sa kumulantima 3, 7 i 12). Izborom ova 3 obeležja, stekli su se uslovi da mreža uspešno klasificuje svih 7 korišćenih modulacija.

#### IV. NEURALNA MREŽA KAO KLASIFIKATOR

Za klasifikaciju signala na osnovu gore određenih 6 obeležja koristi se neuralna mreža. U literaturi su predlagane različite arhitekture za rešavanje ovog problema: od višeslojnog preceptronu (*MLP-Multi-layer Perceptron*) [1], do RBF (*Radial Basis Function*) [2], [3] i SOFM (*Selforganizing Feature Map*) [6] mreža. Arhitektura koja se u ovom radu predlaže je MLP sa 2 skrivena sloja od po 10 i 8 neurona svaki. Neuroni u ovim slojevima imaju odgovarajuće aktivacione funkcije oblika hiperboličkog tangensa, dok 7 izlaznih neurona (po jedan za svaki tip modulacije) imaju linearnu aktivacionu funkciju. Neuralna mreža kao rezultat klasifikacije daje onu modulaciju čiji odgovarajući neuron na svom izlazu daje najveću vrednost.

Korišćeni MLP ima BP (*backpropagation*) metod treniranja, koji za učenje koristi *Levenberg-Marquardt*-ov algoritam.

#### V. SIMULACIJA

##### A. Postavka

Za simulaciju gore opisanog metoda korišćen je programski paket MATLAB. U okviru njega generisan je određen broj slučajnih simbola sa frekvencijom  $F_d$ , koji su zatim modulisani jednom od sledećih vrsta modulacije: 2PSK, 4PSK, 16QAM, 64QAM, 2FSK, 4FSK i 4ASK. Korišćena je standardna MATLAB funkcija za modulaciju digitalnog signala. Ona mapira slučajni digitalni signal u analogni, koji je odabiran sa frekvencijom  $F_s$  i zatim modulisan nosiocem frekvencije  $F_c$ . Frekvencijom  $F_s$  se odabira i modulisani signal na mesto prijema. Zbog realizacije pomenute funkcije u MATLAB-u, neophodno je da frekvencija  $F_s$  bude celobrojni umnožak frekvencije kojom se generišu simboli ( $F_d$ ) i da bude zadovoljeno  $F_s > F_c > F_d$ . U simulaciji je odabrano da brzina generisanja slučajnih simbola bude 9600 simbola u sekundi ( $F_d$ ), dok je za frekvenciju  $F_s$  uzeta 32 puta veća vrednost (307,2kHz). Konačno, proizvoljno je iz dozvoljenog opsega za vrednost frekvencije  $F_c$  odabrano 12kHz.

Vrednosti frekvencija  $F_d$ ,  $F_c$  i  $F_s$  odabrane su tako da se izdvajanje obeležja za potrebe klasifikacije može obaviti dovoljno brzo sa stanovišta simulacije. Isti rezultati očekivani su i za mnogo veće bitske brzine i frekvencije nosioca (kakve se praktično koriste u modernim telekomunikacijama) uz upotrebu veće procesorske snage.

Ovako modulisani signal propušten je kroz simulaciju kanala koji u signal unosi beli aditivni Gausov šum (AWGN) vrednosti od 0dB, 5dB, 10dB, 20dB i 50dB, a

zatim su iz njega na prijemu generisana obeležja koja su prosledena klasifikatoru. Obeležja se generišu na osnovu 4096 odbirka primljenog modulisanog signala. Simulacija je vršena za trajanje signala od 100s (960000 simbola), tako da je sa frekvencijom odabiranja od 307,2kHz formirano 7500 realizacija obeležja za svaku od modulacija, odnosno 52500 realizacija ukupno.

Od 52500 navedenih realizacija, pošto su pomešane, trećina je iskorišćena za trening MLP-a, trećina je korišćena za proces validacije, dok je trećina iskorišćena za formiranje test signala, koji su pokazivali postignut nivo generalizacije u mreži. Testovi su vršeni u maksimalnom broju od 10000 epoha, ali on nikada nije dostizan jer se treniranje uvek završavalo ili postizanjem cilja ili prekidom usled procesa validacije na broju epoha koji je uvek bio dosta manji od 1000.

Na kraju za svaku od modulacija pojedinačno još jednom je izvršena simulacija kroz iztreniranu mrežu, da bi se videlo kako se ponašanje klasifikatora menja u zavisnosti od odabrane modulacije.

### B. Rezultati i njihova analiza

U okviru tabele 2 zabeleženi su rezultati ostvareni na trenig, validacionom i test skupu. Iz priložene tabele se uočava da mreža čak i pri veoma niskim odnosima signal/šum beleži sasvim zadovoljavajuće rezultate od 84% za 0dB do 90% za 5dB, dok je za signal veći od 10dB taj učinak gotovo stoprocentan.

TABELA 2: REZULTATI SIMULACIJE NA UKUPNOM UZORKU.

Rezultat (%)	0dB	5dB	10dB	20dB	50dB
Trening	84.94	90.65	99.25	100	100
Validacija	84.22	90.23	99.01	100	100
Test	84.39	90.42	99.11	99.99	100
<b>Ukupno</b>	<b>84.52</b>	<b>90.43</b>	<b>99.14</b>	<b>99.99</b>	<b>100</b>

U okviru tabele 3 dati su, pak, rezultati postignuti na pojedinačnim modulacijama. Tu se zapaža da se nešto lošiji rezultati postižu kod niskih odnosa signal/šum u slučajevima 4PSK i 4FSK modulacija, gde su vrednosti oko 50 %. Štaviše, detaljnija analiza pokazuje da se ti niski procenti isključivo posledica mešanja upravo ova dva tipa modulacije od strane mreže.

TABELA 3: REZULTATI SIMULACIJE PO POJEDINAČNIM MODULACIJAMA.

Rezultat (%)	0dB	5dB	10dB	20dB	50dB
4PSK	58.59	80.24	99.99	99.99	100
2FSK	83.99	99.93	100	100	100
16QAM	100	88.37	100	100	100
2PSK	98.73	88.15	100	100	100
64QAM	100	100	100	100	100
4ASK	99.83	99.99	100	100	100
4FSK	52.67	76.80	93.97	100	100
<b>Ukupno</b>	<b>84.83</b>	<b>90.50</b>	<b>99.14</b>	<b>99.99</b>	<b>100</b>

U izboru tipova digitalnih modulacija za klasifikaciju,

izostavljena je 2ASK modulacija. Razlog tome leži u činjenici da je konstelacija ovog signala identična 2PSK modulaciji i skup obeležja koji je u ovom radu predložen nije pokazivao sposobnosti njihovog razdvajanja.

### VI. ZAKLJUČAK

Rezultati prikazani u ovom radu pokazuju da se pri dobrom izboru obeležja i odgovarajuće arhitekture neuralne mreže mogu postići veoma dobri rezultati u klasifikaciji, čak i pri niskim odnosima signal/šum.

Predmet daljeg proučavanja može biti realizacija ekstraktora obeležja, koji će biti u stanju da koristi statističke osobine modulisanih signala (recimo posebno mogu biti interesantne osobine ciklostacionarnosti) i koji će biti u stanju da radi i u oblastima sa još nižim odnosom signal/šum. Od interesa je i realizacija ekstraktora koja bi zahtevala manje procesorske snage.

Takođe, same neuralne mreže sa svojim sposobnostima samoorganizovanja, mogле bi imati primenu u realizaciji jednog takvog ekstraktora.

### LITERATURA

- [1] M.L.D. Wong, A.K. Nandi, *Automatic Digital Modulation Recognition Using Artificial Neural Network and Genetic Algorithm*, Signal Processing, vol. 84, 2004.
- [2] B. Le, T.W. Rondeau, D. Maldonado, C.W. Bostian, *Modulation Identification Using Neural Networks For Cognitive Radios*, SDR Forum Technical Conference, 2005.
- [3] C. Jian, K. Yonghong, L. Jiandong, F. Fenglin, *Neural Network Application in Automatic Recognition of Communication Signals*, ICCIMA03, 2003.
- [4] Y. Ye, M. Wenbo, *Digital Modulation Classification Using Multi-layer Perceptron and Time-Frequency Feature*, Journal of System Engineering and Electronics, vol. 18, 2007.
- [5] A.V. Rosti, *Statistical Methods in Modulation Classification*, Tampere University of Technology, M.Sc. Thesis, 1999.
- [6] X. Yang, *An Enhanced Method ForAutomatic Recognition and Identification of Digital Modulations*, DELTA04, 2004.
- [7] D. Drajić, *Uvod u statističku teoriju telekomunikacija*, Akademika misao, Beograd, 2000.
- [8] S. Haykin, *Neural Networks-A Comprehensive Foundations*, Prentice Hall, New Jersey, 1999.

### ABSTRACT

This paper presents a method for automatic recognition of digital modulated signals, that could be significant in Software Defined Radio, as well as in Cognitive Radio. We reviewed some of the, in literature, often used methods for feature extraction from the signal, that can later be used for classification with ANN. Then, we proposed some new features and the architecture for ANN that should use this features for classification. Finally, we showed results of the simulation that separates 7 types of digital modulation with SNR of 0, 5, 10, 20 and 50dB.

### Application of Artificial Neural Networks for Automatic Digital Modulation Recognition in Software Defined and Cognitive Radio

M. Roganović, A. Nešković, N. Nešković