

---

Danilo Đokić i Milomir Stefanović

# Poređenje klasičnih klasifikacionih metoda, konvolucionih neuronskih mreža i mašina sa vektorima podrške za detekciju P300 stimulusa na primeru P300 spelera

---

*Cilj ovog rada je poređenje metoda za detekciju P300 signala i primena tog detektora za implementaciju P300 spelera. Poređena su 4 metoda za detekciju signala i to: Pearsonov korelacioni metod (PCM), klasifikator sa oštrim histerezisom (threshold), konvolucione neuronske mreže (CNN) i maštine sa vektorima podrške (SVM). Korišćena baza preuzeta je sa BCI Competition III. Referentne metode su pokazale tačnost PCM 78% za detekciju signala i 42% za detekciju slova, a threshold 59% za detekciju signala i 44% za detekciju slova. Najveća tačnost za detekciju signala dobijena je korišćenjem SVM (96%), a za detekciju slova CNN (75%).*

---

## Uvod

P300 speler (Farwell i Donchin 1988) je jedno od sredstava komunikacije za ljude koji nisu sposobni da pišu i govore (npr. onima koji boluju od amitrofične lateralne skleroze – Lou Gehrigove bolesti). P300 speler dobija potrebne podatke o moždanim aktivnostima preko uređaja koji se zove elektroencefalograf (EEG). Elektroencefalograf (EEG) je aparat koji registruje električnu aktivnost mozga (neurona). Kada se grupa neurona u nekom delu glave aktivira (tj. kada možak počne ubrzano komunikaciju sa tim delom neurona) potencijal na tom delu glave se povećava. EEG beleži te potencijale pomoću elektroda koje su postavljene na glavi, tj. meri napon između dve elektrode na glavi. Amplituda ovih signala je od 10–200 µV, a frekvencija 0.05–40 Hz (Dintern *et al.* 2014). Tipovi promena EEG signala pod dejstvom mentalnog napora su evocirani potencijali (vremenski domen) i promena zastupljenosti talasa (frekvencijski domen).

Tipično, elektrode koje vrše akviziciju signala postavljaju se na glavu po sistemu poznatom kao 10/20 (koji je opisan u nastavku). Broj elektroda varira u intervalu 8–128, pa i više. Pokazuje se da je tokom prvih 200 ms u signalu prisutan isključivo fiziološki odziv na stimulus, dok se u ostatku vremena javljaju prve posledice obrade signala u mozgu. Posledice se uglavnom javljaju u vidu endogenih potencija koji najčešće predstavljaju

---

Danilo Đokić (1997),  
Kragujevac,  
Kamenička 5/2, učenik  
4. razreda Prve  
kragujevačke gimnazije

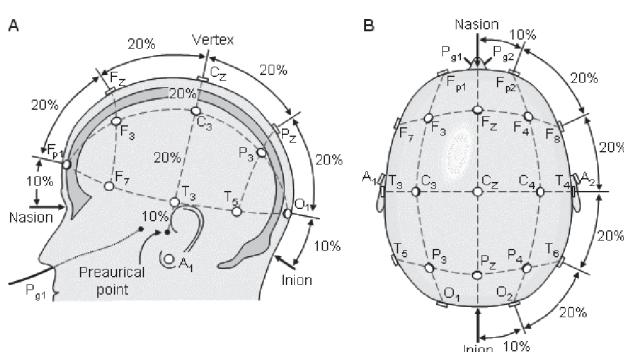
Milomir Stefanović  
(1999), Kragujevac,  
Obilićeva 4, učenik 2.  
razreda Prve  
kragujevačke gimnazije

MENTORI:

Gavrilo Andrić, student  
Elektrotehničkog  
fakulteta Univerziteta u  
Beogradu

Miloš Stojanović, dipl.  
ing., ISP

značajne kratkotrajne impulse signala, a posebno se ističu po trenutku pojavljivanja. Evocirani potencijali se imenuju na osnovu smera deflekcije i njihovog trenutka javljanja (merenog u milisekundama od pojave stimulusa) (SMD 2011). Jedan od značajnijih, signala je P300 stimulus koji se povezuje sa procesom donošenja odluka i uočavanja očekivanih promena. P300 stimulus je pozitivan pik koji se javlja 300 ms nakon stimulusa. Ovakav princip može se, uz odgovarajuću tehničku realizaciju, koristiti za dizajniranje uređaja koji može omogućiti ljudima da se pismeno izražavaju. Tehnička realizacija se sastoji iz ekrana (slika 2) na kome se prikazuje crna matrica sa belim (zatamnjениm) slovima. Nasumično se intenzifikuju (osvetljavaju) redovi i kolone te matrice i tada se okida snimanje signala. Nakon 300 ms od intenzifikacije očekuje se pojava P300 stimulusa, što podrazumeva da je detekcija slova ekvivalentna preciznoj i brzoj detekciji, uz informaciju da je ispitanik oko 300 ms ranije gledao u slovo koje je bilo osvetljeno (Farwell i Donchin 1988). Intenzifikacija se vrši učestanošću od oko 5 Hz (Ceccotti i Graser 2011). P300 speler koristi *oddball* paradigmu, te nagoveštava da ponavljanje sekvenci audio ili vizuelnih stimulusa u izobilju devijantnih stimulusa poboljšava mogućnost ispravne detekcije. U literaturi (Dintern *et al.* 2014) je pokazano da se P300 stimulus ne javlja tačno nakon 300 ms, već u nekom opsegu oko 250–450 ms, uglavnom zavisno od starosti ispitanika. Takođe, od starosti subjekata zavisi i amplituda, pa čak i oblik tog signala. Iz ovih razloga nije moguće kreirati jednostavni detektor koji bi radio na principu oštrog histerezisa (Farwell i Donchin 1988), te je potrebno formirati obimne test i trening setove koji bi se iskoristili za formiranje klasifikatora koji bi obavljaо posao detekcije stimulusa.



Slika 1. Prikaz elektroda na glavi sa njihovim oznakama (Sharbrough *et al.* 1991)

Figure 1. Electrodes on the head with their markings (Sharbrough *et al.* 1991)

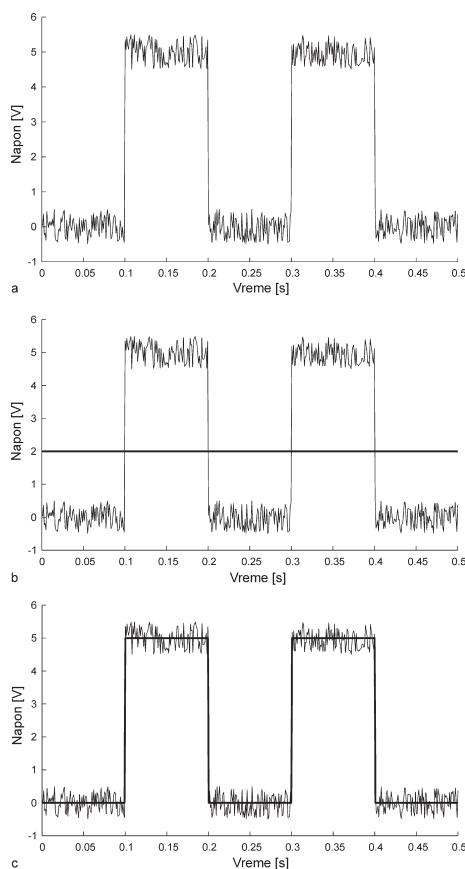
Internacionalni 10/20 sistem definiše ime svake elektrode koje se sastoji od lokacije i indeksa (SMD 2011). Ako je prvo slovo označke elektrode F, elektroda je na frontalnom delu, T ako je u temporarnom delu, P ako je u parijetalnom delu, C ako je u centralnom delu, a Z ako je na centralnoj liniji. Indeks je paran ako je elektroda na desnoj hemisferi mozga, a neparan ako je ne levoj hemisferi mozga (slika 1).

Radi snimanja navedenih signala potreban je adekvatan hardver koji vrši pojačavanje i filtriranje. Nakon toga takvi, kondicionirani signali dovede se na analogno-digitalni konvertor (ADC) zbog potreba digitalne obrade signala.

## Pregled korišćenih metoda

### Klasifikator zasnovan na principu oštrog histerezisa

Threshold ili prag je najjednostavnija vrsta binarnog klasifikatora. Naime, vrednost praga se određuje tako da se na osnovu nje sve tačke u prostoru karakteristika mogu razdvojiti u dve klase: sa vrednostima karakteristika većim ili manjim od praga. Ovakav sistem se npr. može koristiti za oticanje šuma kod binarnog signala. Uzmimo da je aktivno stanje sistema koji se kontroliše 5 V, a neaktivno stanje 0 V. Zbog prisustva šuma, signal izgleda kao na slici 2a. Kada se izračuna srednja vrednost zašumljenog signala, može se dobiti prag sa grafika na slici 2b. Ako je vrednost signala ispod praga, nova vrednost signala je 0V, a ako nije, onda je nova vrednost signala 5 V. Na taj način dobijamo signal sa slike 2c. Ovo je prost primer primene klasifikatora sa oštrim histerezisom.



Slika 2.

a – zašumljen signal  
b – zašumljen signal sa granicom  
c – zašumljen i čist signal

Figure 2.

a – signal with noise  
b – signal with noise and threshold  
c – signal with noise and clean signal

Najčešćegledniji klasifikator za detekciju P300 signala i klasifikaciju samih slova je klasifikator sa oštrim histerezisom (threshold). Pošto se teotski signal P300 javlja 300 ms posle stimulsa, najjednostavniji način da se proveri da li su se javile neke velike promene u periodu kad se on očekuje, tj. od 250 do 450 ms, je ovakav klasifikator. Iz tog razloga se za prag uzima razlika aritmetičkih sredina odbiraka signala u periodima 250–450 i 450–1000 ms, a period 0–250 ms se odbacuje, jer se u tom periodu javlja signal koji daje informacije o fizičkim karakteristikama stimulsa. Ovaj prag se određuje na osnovu podataka iz trening seta. Epoha je vremenski period trajanja  $\tau$  nakon stimulusa (uzeto je  $\tau = 1$  s). Pozitivna epoha je ona koja se javlja na pozitivan stimulus (osvetljeno je slovo koje ispitanik gleda), inače je negativna. Neka je  $a_c$  srednja vrednost svih epoha snimanih na kanalu  $n$  za dat simbol  $c$  (srednja vrednost svih epoha stimulusa reda i kolone koje sadrže taj simbol) tokom jednog snimka. Klasifikator se zasniva na metrički data sa:

$$\delta_t = a|_{t1}^{t2} - a|_{t3}^{t4}$$

Pri čemu se sa  $a|_{t1}^{t2}$  označava srednja vrednost signala  $a$  u vremenskom intervalu  $[t_1, t_2]$ . Konačno, klasificuje se slovo s za koje je najveća vrednost metrike  $\delta_s$ . Glavna mana ovog klasifikatora je to što je neotporan na šum, kao i to da se signal ne javlja uvek u istom vremenskom trenutku, što perioda P300 signala nije uvek ista kao ni amplituda. Dodatnim filtriranjem i usrednjavanjem odnos signal-šum se povećava, te se očekuje veća tačnost kako se više signala usrednjava. Zbog mana koje su navedene, u praksi se ovakav metod skoro nikada ne koristi, dok je u ovom radu on implementiran kao osnovni referentni metod.

### **Pearsonov korelacioni metod (PCM)**

Koeficijent korelacije predstavlja statističku povezanost dva parametra kojima se opisuje dati skup podataka. Pošto se klasifikacija vrši nad usrednjениm epohama, koeficijenti korelacije služe da odrede značaj (udeo) svakog od odbiraka usrednjene epohe. Konkretno, za svaki od vektora iz trenining seta izdvaja se epoha koja se koreliše sa oznakama trening seta i time određuje koeficijent korelacije  $p_i$  (Krusienski *et al.* 2006). Za svaki od odbiraka određuje se ovakva korelacija, iz čega se dobija vektor:

$$\vec{p} = [p_1 \ p_2 \ p_3 \ \dots \ p_n]$$

Kada se vrši klasifikacija nekog novog vektora karakterističnih obeležja  $\vec{x}$  (iz test seta), određuje se vrednost  $\vec{p} \cdot \vec{x}$ . Za sve srednje epohe po stimulusima ( $\vec{s}_1, \vec{s}_2, \vec{s}_3, \dots, \vec{s}_{12}$ ) određuje se  $\vec{p} \cdot \vec{s}$ . Red i kolona u kojima se javio P300 određuju se na osnovu izraza:

$$r = \arg \max_{i \in 1, \dots, 6} \vec{s}_i \cdot \vec{p}; \quad c = \arg \max_{i \in 1, \dots, 72} \vec{s}_i \cdot \vec{p}.$$

### **Mašine sa vektorima podrške (SVM)**

Mašine sa vektorima podrške (engl. Support Vector Machines – SVM) su jedan od modela koji se koriste za treniranje klasifikatora i regresora u

oblasti mašinskog učenja (engl. Machine learning) (Cortes i Vapnik 1995). U svojoj osnovnoj formi, SVM je deterministički model za treniranje klasifikatora koji određuje pripadnost elementa jednoj od dve linearne separabilne klase – tzv. linearni binarni klasifikator. Algoritam je zasnovan na optimizaciji razdelnih hiperravnih između skupova označenih (+ i -) vektora karakterističnih obeležja u prostoru. Optimizacija se vrši po parametru udaljenosti najbližih tačaka od te ravni. Posmatrajmo skup parova vektora karakteristika i oznaka:

$$F = \{(\vec{x}_i, y_i) : i \in 1 \dots m\}$$

gde je  $m$  – broj članova trening seta ( $m = |F|$ ). Kako je u pitanju binarna klasifikacija, usvojićemo da je  $y_i = \pm 1$ . U  $n$ -dimenzionom prostoru može se pokazati da je hiperravan određena vektorom  $\vec{w}$  i skalarom  $b$  pri čemu sve tačke  $\vec{x}$  koje pripadaju toj hiperravni određene izrazom:

$$\vec{w} \cdot \vec{x} + b = 1$$

gde je modulom vektora  $\vec{w}$  određena udaljenost hiperravnih od tačke. Mogu se izdvojiti dva skupa tačaka sa dve strane ove hiperravnih:

$$F_1 = \{\vec{x} : \vec{w} \cdot \vec{x} + b > 1\}$$

$$F_{-1} = \{\vec{x} : \vec{w} \cdot \vec{x} + b < -1\}$$

Treniranje se sastoji iz izračunavanja maksimalne dužine vektora  $\|\vec{w}\|$ , tako da sve tačke  $(x_i, y_i = 1) \in F_1$  i sve tačke  $(x_i, y_i = -1) \in F_{-1}$ .

Dizajnira se klasifikator čiji prostor karakterističnih obeležja čine vektori karakterističnih obeležja sastavljeni od spojenih odbiraka usrednjениh u pretprocesiranih epoha sa više kanala. Varira se broj usrednjениh epoha u intervalu  $n \in [1, 15]$ . Kako za svako slovo postoje dva pozitivna stimulusa (red i kolona), to postoje ukupno  $2 \times 15$  pozitivnih epoha. Od ukupno  $2 \times 15$  epoha, formira se ukupno  $m = \lfloor 2 \times 15 / n \rfloor$  pozitivnih vektora karakterističnih obeležja, grupisanjem epoha (koje se sve smatraju jednakima). Sa druge strane, postoji ukupno deset negativnih stimulusa (svi ostali redovi i kolone), od kojih se nasumično biraju dva stimulusa i iz njih se na sličan način dobijaju  $m$  negativnih vektora karakterističnih obeležja. To se čini iz razloga da bi uslovi pod kojima se formiraju pozitivni vektori i negativni vektori karakterističnih obeležja zavisili isključivo od prisustva P300 stimulusa. Ukoliko bi se usrednjavao nejednak broj epoha onda bi pozitivni i negativni vektori karakterističnih obeležja bili razdvojivi i samo na osnovu varijanse – zbog stohastičkog šuma, koji je znatno veći u tako formiranim pozitivnim odbircima. Klasifikator se trenira SMO metodom sa linearnim kernelom.

## Konvolucione neuronske mreže

Neuronska mreža je jedan oblik implementacije sistema veštačke inteligencije, koja je nastala kao pokušaj da se simulira rad ljudskog mozga. Model se sastoji od slojeva koji mogu biti:

- Ulazni sloj – sloj u kojem se nalaze ulazni neuroni koji pretstavljaju ulazne podatke;
- Skriveni sloj (potpuno povezani slojevi) – sloj koji služi za procesiranje podataka kao i na samu kompleksnost mreže;
- Izlazni sloj – sloj u kojem se nalaze izlazni neuroni koji daju izlaz celog sistema.

Čvorovi se nazivaju neuroni. Svaki čvor je povezan sa čvorom u sledećem sloju kroz vezu kojoj je dodeljena određena težina. Treniranje neuronske mreže se sastoji od toga da se ti težinski koeficijenti međusobno adaptiraju tako da oslikavaju realnu vezu između ulaznih atributa i izlazne vrednosti. Algoritam koji se najčešće koristi za treniranje mreže je back-propagation algoritam.

Konvolucione neuronske mreže u svojim konvolucionim slojevima vrše filtriranje podataka koji su joj dati na ulazu (najčešće slike).

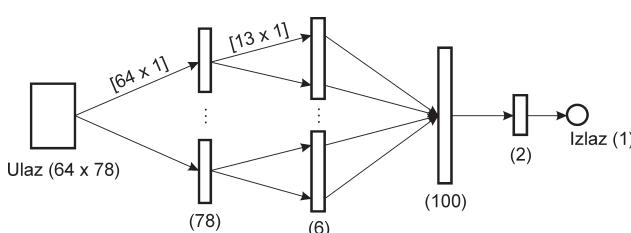
Konvolucione neuronske mreže se razlikuju od običnih neuronskih mreža u tome što imaju više vrsta slojeva, i što njima nije potrebno dovoditi neke unapred projektovane karakteristike, već se mreža sama trenira i uči koje su karakteristike iz ulaznog podatka najbitnije za nju. Slojevi koji služe mreži za učenje karakteristika ulaznih podataka zovu se konvolucioni. Kada se ovakve mreže treniraju one za razliku od običnih neuronskih mreža koje menjaju samo težinske koeficijente, menjaju i kernele滤器 kojom vrši konvoluciju. Filtriranje je kovolucija slike predefinisanom filter matricom:

$$g(x, y) = \sum_{i=-w}^{i=w} \sum_{j=-w}^{j=w} h(i, j)f(x-i, y-j) \quad (7)$$

gde je  $f$  podatak koji se filtrira,  $g$  izlaz filtriranja,  $h$  kernel filtra kojim se vrši filtriranje dimenzija  $(2w + 1)(2w + 1)$ .

Konvolucione neuronske mreže pored ulaznih, izlaznih, skrivenih i kovolucionih slojeva, često sadrže i slojeve združivanja kao i slojeve maksimalne verovatnoće koji služe za računavanje verovatnoće da je izlaz ono što je očekivano itd. (Ceccotti i Graser 2011). Ovakvi sistemi mogu da se koriste za probleme kao što su: prepoznavanje cifara, prepoznavanje objekta na slici, prepoznavanje scene itd. (Ceccotti i Graser 2011).

Implementirana konvolucionna neuronska mreža ima 6 slojeva, i to jedan ulazni, dva konvolucionia, dva skrivena, jedan sloj veće verovatnoće (slika 3).



Slika 3. Arhitektura korišćene mreže

Figure 3. Architecture of the used network

Da bi se uštedelo vreme izvršavanja datog zadatka potrebno je izvršiti decimovanje na 120 Hz. Znajući da se P300 signal javlja između 250 i 450 ms uzima se interval od 650 ms nakon stimulsa.

Arhitektura mreže opisana je na sledeći način:

1. Ulagani sloj. U ulagani sloj dolaze podaci u obliku matrice dimenzija  $64 \times 78$ . Ova matrica pretstavlja matricu od 64 signala, tj. signala sa svih elektroda u prvih 650 ms posle stimulsa.

2. Prvi konvolucioni sloj. Svaka od 78 kolona filtrira se drugačijim filterom dimenzija  $64 \times 1$  koji se u toku treniranja mreže menja. Na izlazu iz mreže dobija se 78 mapa karakterističnih obeležja čije vrednosti predstavljaju vrednosti svake kolone posle filtriranja. Fizički smisao ovog filtriranja je pokušaj da se odrede koji su odbirci važni za klasifikaciju. Na ovaj način ako se svaka mapa gleda kao jedna vrednost dobija se signal dužine 78 odbiraka.

3. Drugi konvolucioni sloj. Šest parova od po 13 mapa karakterističnih obeležja filtrira se filterom dimenzija  $13 \times 1$ . Na ovaj način dobijaju se novih 6 konvolucionih mapa karakterističnih obeležja. Sada svaka vrednost predstavlja neki karakterističan broj za svakih 108 ms snimka posle stimulsa.

4. Prvi skriveni sloj. To je sloj od 100 skrivenih neurona. Ovakav sloj javlja se i kod običnih neuronskih mreža. Uloga ovih neurona jeste da od 6 informacija koje se dobijaju na ulazu odrede koja vrednost ima najveću važnost i koje vrednosti će upisati u sledeći sloj.

5. Drugi skriveni sloj. To je sloj od 2 skrivena neurona. Ovaj sloj daje informaciju od tome da li je signal P300 ili nije P300.

6. Sloj maksimalne verovatnoće. To je sloj koji na osnovu prethodna dva neurona izračunava verovatnocu da signal na ulazu sadrži P300 ili da ne sadrži isti. Ovaj sloj ima jedan izlaz. Izlaz ovog sloja je 0 ako je veća verovatnoća da na izlazu nema P300 signala ili 1 ako je veća verovatnoća da na ulazu ima P300 signala.

## Cilj istraživanja

Cilj ovog rada je poređenje metoda za detekciju P300 signala i primena tog detektora za implementaciju P300 spelera. Analizirana su četiri metoda za detekciju signala: klasifikator sa oštrim histerezisom (threshold), Pearsonov korelacioni etod (PCM), konvolucione neuronske mreže (CNN) i mašine sa vektorima podrške (SVM). Cilj je bio da uporede njihove performanse za šta su korišćene metrike tačnost, preciznost i odziv.

Hipoteze:

1. Klasifikator sa oštrim histerezisom će po svim metrikama raditi lošije od preostala tri metoda jer se P-300 signal ne javlja tačno u trenutku 300 ms, već u relativno velikom opsegu od 250-450 ms a zavisno od stvarnosti ispitnika (Dinteren *et al.* 2014) dok taj klasifikator to vreme usredjava.

2. Konvolucione neuronske mreže (CNN) i mašine sa vektorima podrške (SVM) će imati veću tačnost od Pearsonovog korelacionog metoda (PCM), jer PCM klasifikator efektivno usrednjava trenutak dešavanja

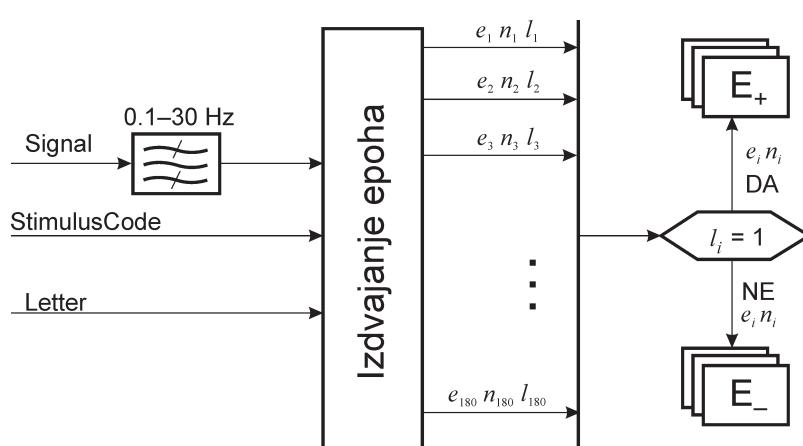
P-300 signala što implicira da se P-300 signal mora javljati u približno istom trenutku, dok to nije uslov kod metoda mašinskog učenja.

3. Konvolucione neuronske mreže (CNN) će imati veću tačnost od mašina sa vektorima podrške (SVM); što je izvedeno iz principa funkcionisanja oba metoda (Cecotti i Graser 2011).

## Materijal i metod

### Predprocesiranje signala

Korišćena baza sadrži 180 snimaka trajanja 32 sekunde. Tokom svakog od snimaka, ispitanik gleda u monitor, a cilj mu je da otkuca tačno jedno slovo, određeno rednim brojem snimka. U daljem objašnjavanju, sve oznake se odnose na sliku 4. Svaki snimak (označen kao signal) sniman je učestanostu odabiranja 240 Hz, ukupno 7680 odbiraka). Uz svaki snimak postoji i signal StimulusCode koji definiše koji je stimulus pobuđen tokom određenog odbirka. Dodatno, postoji i binarni signal Letter koji određuje na kojim je od odbiraka aktivran pozitivan stimulus. U nastavku opisuje se tretman jednog snimka do dobijanja vektora karakterističnih obeležja.



Slika 4.  
Prikaz  
predprocesiranja

Figure 4.  
Preprocessing

Za sve snimke, vrši se filtriranje filtrom propusnikom opsega učestanosti 0.1–30 Hz.

U svakom snimku, svaki od 12 stimulusa se javlja po 15 puta; ukupno 180 epoha. Da bi se snimak obradivao prvo je potrebno izdvojiti i označiti ove epohe. Na osnovu StimulusCode signala, za svaku epohu se izdvaja:

- Vektor  $e$  – odbirci epohe (dim  $e = 240$ );
- Ceo broj  $n$  – redni broj stimulusa ( $0 < n \leq 12$ );
- Booleova promenljiva  $l$  – da li je tokom epohe pobuđen pozitivan stimulus.

Nakon izdvajanja formirana su dva skupa  $E_+$  (pozitivnih epoха) i  $E_-$  (negativnih epoха), pri čemu je jasno:

$$\begin{aligned} E_+ &= \{(\mathbf{e}_i, n_i) : l_i\} \\ E_- &= \{(\mathbf{e}_i, n_i) : -l_i\} \end{aligned}$$

Potrebno je primetiti da je  $|E_+| = 2 \times 15$  i da je  $|E_-| = 13 \times 5$ , te se može smatrati da je  $|E_-| \gg |E_+|$ , odnosno da se ovi skupovi u celini ne mogu bez izdvajanja koristiti za formiranje odgovarajućih test i trening skupova, jer bi takvi skupovi bili nebalansirani (sadržali značajno više negativnih od pozitivnih epoha).

Redukovani negativni skup epoha je bilo koji skup  $E_-^{(r)}$  takav da je  $|E_-^{(r)}| = |E_+|$  i  $E_-^{(r)} \subset E_-$ . Sada se od skupa  $E = E_+ \cup E_-^{(r)}$  formiraju osnovni test i trening skupovi, kao njegove binarne particije,  $E_{\text{test}}$  i  $E_{\text{train}}$ , koji zadovoljavaju svojstva:

$$E_{\text{test}} \cap E_{\text{train}} = \emptyset, |E_{\text{test}}| : |E_{\text{train}}| = 100 : 80$$

Dalje se definišu test i trening skupovi usrednjavanih epoha, koji predstavljaju usrednjavane vektore pojedinačnih epoha.

$$E_{n,\text{test}} = \bigcup_{\substack{P \in P_n(E_{\text{test}}) \\ l_i = \text{const}}} \left( \frac{1}{n} \sum_{i \in P} \mathbf{e}_i, l_i \right)$$

$$E_{n,\text{tren}} = \bigcup_{\substack{P \in P_n(E_{\text{tren}}) \\ l_i = \text{const}}} \left( \frac{1}{n} \sum_{i \in P} \mathbf{e}_i, l_i \right)$$

gde je  $P_n(A)$  podskup partitivnog skupa  $P(A)$  koji sadrži samo skupove sa  $n$  elemenata.

## Baza podataka

Baza koja je korišćena u ovom radu preuzeta je sa BCI Competition III takmičenja (Farwell i Donchin 1988). Baza se sastoji od dva ispitanika. Jedan ispitanik je osoba muškog pola starosti 18 godina, a druga je osoba ženskog pola starosti 44 godine. Za svaku osobu snimano je 185 snimaka 100 za test i 85 za trening. Svaki snimak sniman je u sekvencama od po 2.5 s frekvencijom odabiranja od 240 Hz na 64 kanala. Svaki ispitanik gledao je u matricu dimenzija  $6 \times 6$  karaktera. Simboli su bili slova od A do Z brojevi od 0 do 9 i znak za razmak (slika 5). Svaka kolona ili red se u nasumičnoj sekvenci osvetljuju na svakih 150 ms i osvetljeni red ostaje osvetljen 100 ms. Za svako slovo sniman je stimulus 15 puta. Ako se za pozitivnu epohu proglaši epoha u kojoj se javlja P300, a za negativnu ona u kojoj istog nema, važi da u bazi postoji 6 puta više negativnih nego pozitivnih epoha, pa se za metriku uzimaju tri parametra: preciznost, odziv i tačnost. Takođe iz istog razloga potrebno je ispitivati uspešnost za dve vrste detekcije i to za detekciju P300 signala i detekciju samog slova.

## Speler

Speler se sastoji od matrice  $6 \times 6$  koja je sastavljena od različitih simbola (slika 5). Na opisani način, korisnik unosi slovo po slovo. Redovi ili

kolone su osvetljeni 100 ms, a na svakih 175 ms se menja red ili kolona koja se osvetljuje. Vrednosti od 100 i 175 ms preuzete su iz rada (Kruseinski *et al.* 2006). Kada bi se osvetlio karakter koji korisnik zamišlja, na EEG snimku bi se pojavio P300 evocirani potencijal (Kruseinski *et al.* 2006).

A	B	C	D	E	F
G	H	I	J	K	L
M	N	O	P	Q	R
S	T	U	V	W	X
Y	Z	1	2	3	4
5	6	7	8	9	_

Slika 5. Speler matrica  
(Citi *et al.* 2010)

Figure 5. Speller matrix  
(Citi *et al.* 2010)

## Klasifikator slova

Iz jednog test snimka izdvajaju se i obrađuju epohe i one čine skup  $E_{n,\text{test}}$  (u strukturi opisanoj u delu pretprocesiranje). Taj skup se dalje razdeljuje prema epohama i usrednjava. Takvi dobijeni vektori karakterističnih obeležja se klasifikuju. Kao rezultat takve klasifikacije dobija se vrednost koja određuje pouzdanost klasifikacije  $r_i$ ; pri tome,  $r_i$  je veće ukoliko je klasifikator „sigurniji“ da je vektor karakterističnih obeležja u pozitivnoj klasi, i slično je manje ukoliko je „sigurniji“ da je u negativnoj. Ukoliko je  $r_i = 0$ , vektor karakterističnih obeležja je na razdelnoj hiperravni. Kako je poznato da su tačno dva stimulusa pozitivna, i to tačno jedan od u intervalu  $1 \leq n_i = i \leq 6$  i tačno jedan u intervalu  $7 \leq n_i = i \leq 12$ , to je jasno da se dva pozitivna stimulusa mogu odrediti izrazima:

$$n_R^{(+)} = \arg \max_{1 \leq i \leq 6} r_i, \quad n_C^{(+)} = \arg \max_{7 \leq i \leq 12} r_i$$

Pri tome je jasno da na osnovu strukture korisničkog prikaza vrednosti  $n_R^{(+)}$  i  $n_C^{(+)}$  određuju red i kolonu u kojima s nalazi detektovano slovo.

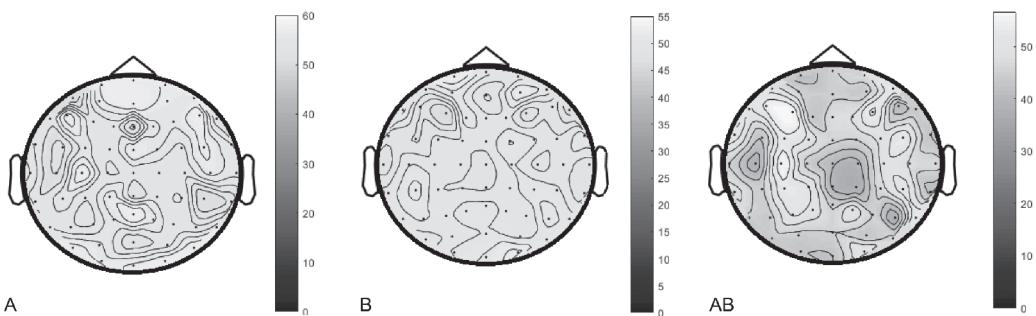
## Rezultati

### Detekcija P300

#### Klasifikator zasnovan na principu oštrog histerezisa

Primenivši opisani metod za detekciju signala koji je usrednjen 15 puta variran je kanal na kom se merenje vrši. Izračunavši tačnost detekcija P300 signala na svakom kanalu za sve kombinacije podataka, topografski su prikazani rezultati na slici 6.

Tačnost detektovanja signala kod subjekta A je 54% kod subjekta B 51%, a kod subjekata A i B zajedno 52%. Koristivši kanal kod koga je dobi-



Slika 6. Klasifikator zasnovan na principu oštrog histerezisa: topografski prikaz tačnosti detektovanja P300 signala kod subjekta A, subjekta B i oba subjekta zajedno (AB)

Figure 6. Threshold: topoplot of accuracy of detection of the P300 signal in subject A, subject B and both subjects A and B (AB)

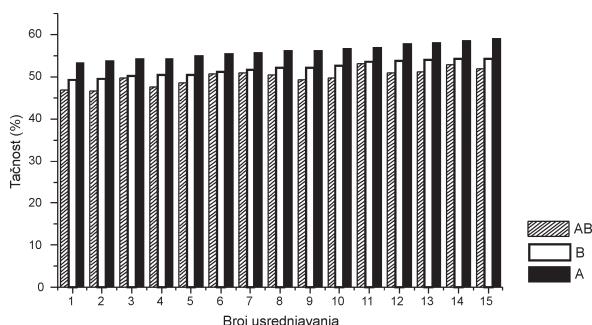
jena najveća tačnost dobijeni su grafici zavisnosti uspešnosti detektovanja P300 signala od broja usrednjavanja, koji su prikazani na slikama 7a–7c.

U prva dva slučaja koja su posmatrana primećen je rast sve tri metrike u odnosu na broj usrednjavanja. Ovim se primećuje da veći broj usrednjavanja pozitivno utiče na posmatrane metrike. Na grafiku koji prikazuje zavisnost broja usrednjavanja od uspešnosti (slike 7a–7c), ovakav rast se sporije i slabije pokazuje. Sažetak rezultata na 15 usrednjavanja prikazan je u tabeli 1.

Tabela 1. Tačnost, preciznost i odziv detektovanja P300 signala za sve kombinacije podataka kod klasifikatora sa principom oštrog histerezisa

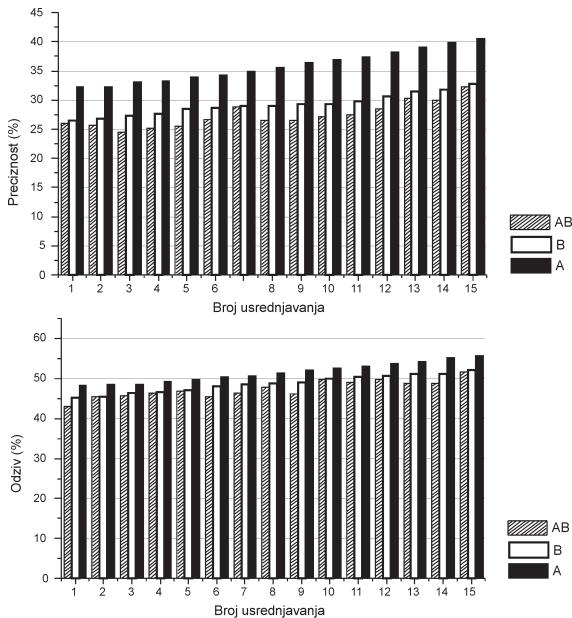
Subjekat	N	Tačnost	Preciznost	Odziv
A	15	59	41	56
B	15	55	32	52
A i B	15	52	32	51

### Pearsonov korelacioni metod



Slika 7a. Zavisnost tačnosti detekcije P300 signala od broja usrednjavanja kod klasifikatora zasnovanog na principu oštrog histerezisa

Figure 7a. Dependance of the accuracy in detecting P300 signal on the number of averaging with threshold



Slika 7b. Zavisnost preciznosti detekcije P300 signala od broja usrednjavanja kod klasifikatora zasnovanog na principu oštrog histerezisa

Figure 7b. Dependance of the precision in detecting P300 signal on the number of averaging with threshold

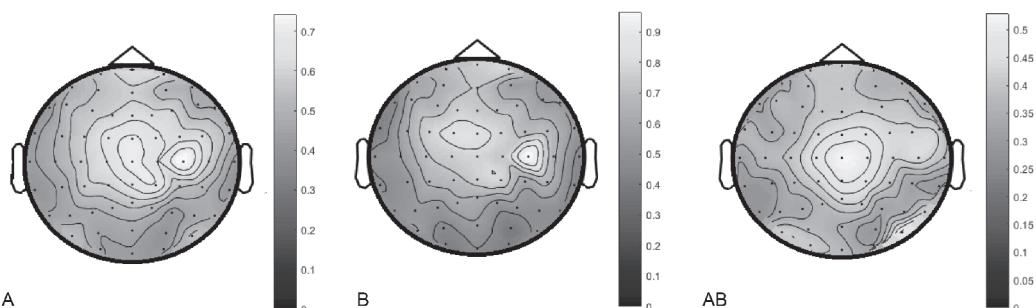
Slika 7c. Zavisnosti odziva detekcije P300 signala od broja usrednjavanja kod klasifikatora zasnovanog na principu oštrog histerezisa

Figure 7c. Dependance of the recall in detecting P300 signal on the number of averaging with threshold

Za svaki kanal izračunavana je tačnost detektovanja P300 signala na svakom kanalu i ovi rezultati prikazani su u obliku topografskog snimka glave na slici 8.

Sa ovih topografskih snimaka jasno se vidi da je najaktivniji deo mozga koji je aktiviran za ovaj proces opet centralni režanj i tačnost opada kako su elektrode dalje od temena glave. Na graficima 9a–9c prikazana je zavisnost posmatrane metrike od broja usrednjavanja.

Ovde je takođe primećeno da tačnost, preciznost i odziv rastu kako broj usrednjavanja raste. I ovde je primećen rastući trend i najveća tačnost javila se na petnaestom usrednjavanju. Sažetak rezultata ovog metoda na 15 usrednjavanja prikazan je u tabeli 2.

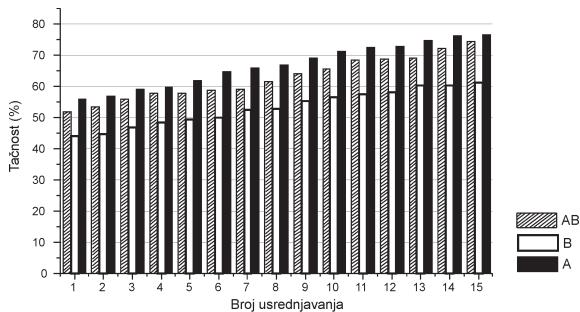


Slika 8. PCM: topografski prikaz tačnost detektovanja P300 signala kod subjekta A, subjekta B i oba subjekta zajedno (AB)

Figure 8. PCM: topoplot of accuracy of detection of the P300 signal in subject A (a), subject B (b) and both subjects A and B (AB)

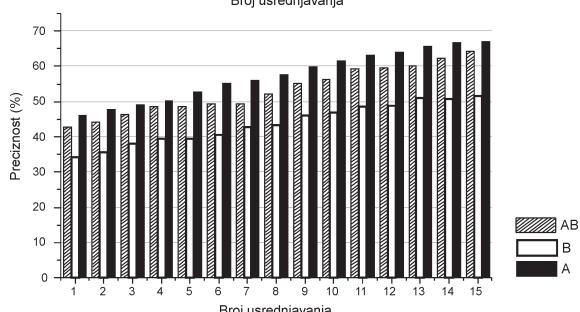
Tabela 2. Tačnost, preciznost i odziv kod subjekata A i B pojedinačno i kod subjekata A i B zajedno kod PCM

Subjekat	N	Tačnost	Preciznost	Odziv
A	15	78%	50%	67%
B	15	62%	32%	52%
A i B	15	74%	36%	63%



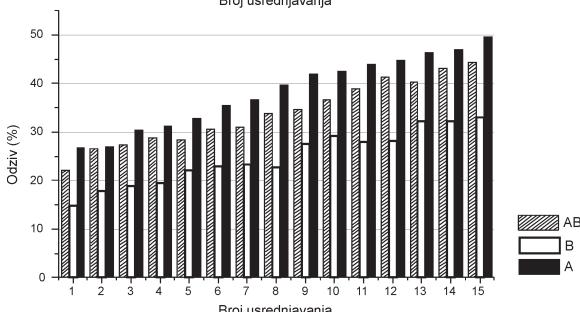
Slika 9a. Zavisnost tačnosti detekcije P300 signala od broja usrednjavanja kod PCM

Figure 9a. Dependance of the accuracy in detecting P300 signal on the number of averaging using PCM



Slika 9b. Zavisnost preciznosti detekcije P300 signala od broja usrednjavanja kod PCM

Figure 9b. Dependance of the precision in detecting P300 signal on the number of averaging using PCM



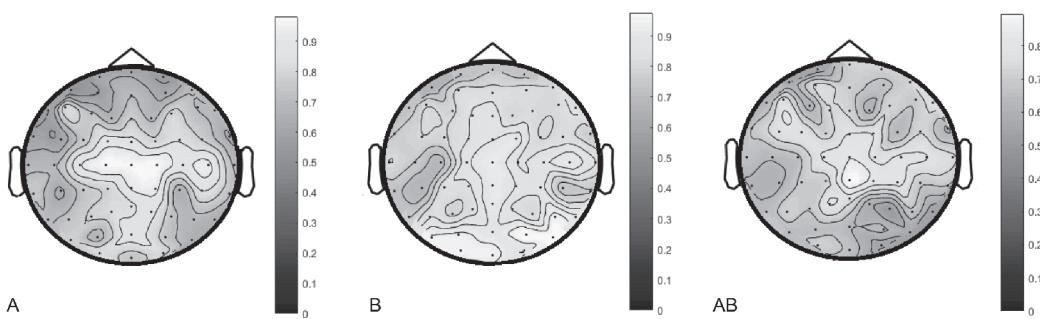
Slika 9c. Zavisnosti odziva detekcije P300 signala od broja usrednjavanja kod PCM

Figure 9c. Dependance of the recall in detecting P300 signal on the number of averaging using PCM

## Mašine sa vektorima podrške

Kao što je prethodno opisano SVM ima mogućnost da radi na jednom ali i na više kanala. Detektujući P-300 signal na samo jednoj elektrodi za sve 3 kombinacije podataka topografski su prikazani rezultati na slici 10.

Jasno se vidi da se kod osobe A najveća tačnost javila na elektrodama koje se nalaze na temenom delu glave. Kod osobe B najveće tačnosti se javljaju pored temenog dela i na potiljačnom delu glave. Tako da je primećena



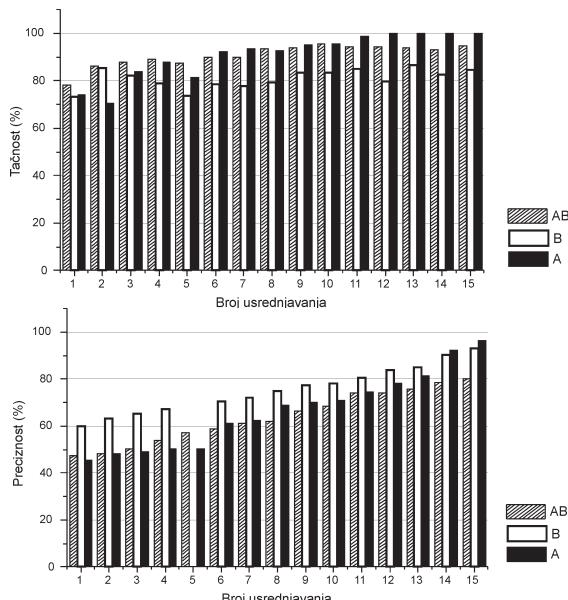
Slika 10. SVM: topografski prikaz tačnosti detektovanja P300 signala kod subjekta A, subjekta B i ova subjekta zajedno (AB)

Figure 1. SVM: topoplot of accuracy of detection of the P300 signal in subject A, subject B and both subjects A and B (AB)

razlika između ova dva subjekta. Najveća tačnost detektovanja P300 signala bila je na elektrodi  $FC_z$  i iznosi 98.5 %. Kod osobe B najveća tačnost – 98% primećena je na elektri  $PO_z$ . Na istoj elektrodi najveća tačnost 90% pojavila se kod pomešanih podataka osoba A i B.

Zatim, uvezvi signale sa 11 elektroda sa kojih je očekivana najveća tačnost (Farwell i Donchin 1988), ispitivana je zavisnost tačnosti, preciznosti i odziva za različit broj usrednjavanja tj. od 1 do 15. Rezultati su prikazani na slikama 11a–11c.

Kod osobe A primećen je trend povećavanja ovih metrika sa povećanjem broja usrednjavanja. Kod osobe B nije primećen isti trend. Kod podataka od osoba A i B zajedno, rastući trend je opet uočen. Najbolji rezultat za sve tri metrike prikazan je u tabeli 3.

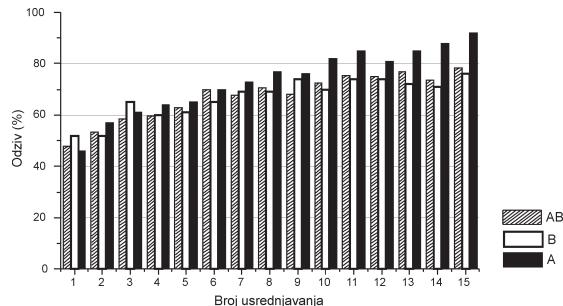


Slika 11a. Zavisnost tačnosti detekcije P300 signala od broja usrednjavanja kod SVM

Figure 11a. Dependance of the accuracy in detecting P300 signal on the number of averaging using SVM

Slika 11b. Zavisnost preciznosti detekcije P300 signala od broja usrednjavanja kod SVM

Figure 11b. Dependance of the precision in detecting P300 signal on the number of averaging using SVM



Slika 11c. Zavisnost odziva detekcije P300 signala od broja usrednjavanja kod SVM

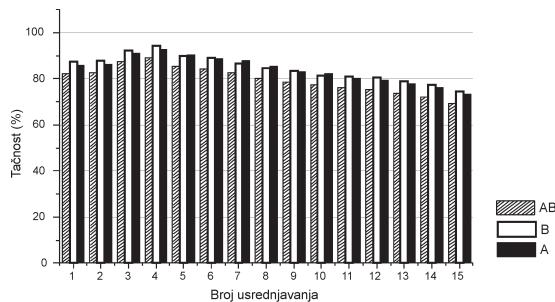
Figure 11c. Dependence of the recall in detecting P300 signal on the number of averaging using SVM

Tabela 3. tačnost, preciznost i odziv kod subjekata A i B pojedinačno i kod subjekata A i B zajedno kod SVM

Subjekat	N	Tačnost	Preciznost	Odziv
A	15	100%	96%	92%
B	13	86%	80%	72%
A i B	15	95%	93%	78%

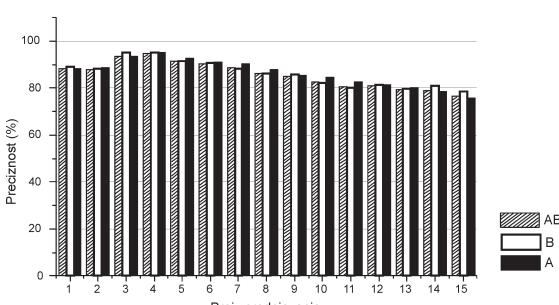
### Kovolucione neuronske mreze

Zavisnost tačnosti, preciznosti i odziva od broja usrednjavanja prikazana je na grafikonima, slika 12. Kako se na osnovu uvodnih razmatranja prepostavlja se da bi ovaj metod trebao da bude invarijantan na starost, mreža je trenirana na subjektima A i B zajedno i testirana na istim.



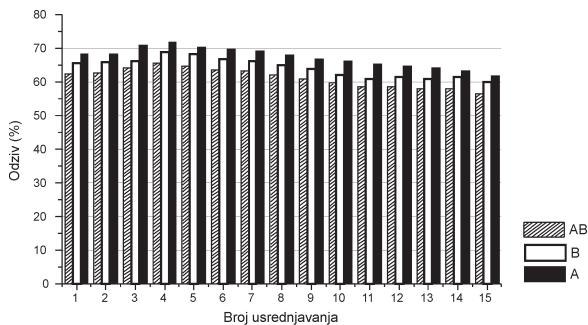
Slika 12a. Zavisnost tačnosti detekcije P300 signala od broja usrednjavanja kod CNN

Figure 12a. Dependence of the accuracy in detecting P300 signal on the number of averaging using CNN



Slika 12b. Zavisnost preciznosti detekcije P300 signala od broja usrednjavanja kod CNN

Figure 12b. Dependence of the precision in detecting P300 signal on the number of averaging using CNN



Slika 12c. Zavisnosti odziva detekcije P300 signala od broja usrednjavanja kod CNN

Figure 12c. Dependence of the recall in detecting P300 signal on the number of averaging using CNN

Na osnovu dobijenih rezultata zaključuje se da konvolucionna neuronska mreža može biti invarijantna na više subjekata akko se mreža trenira na tim istim subjektima. Takođe nije primećen konstantan rast tačnosti, preciznosti i odziva kako je rastao broj usrednjavanja, što je očekivano, jer konvolucionna neuronska mreža ima oko 2000 slobodnih parametara, a kako se broj usrednjavanja povećava tako broj epoha na kojima se mreža trenira smanjuje. Zbog tog razloga ove metrike imaju svoj supremum na 4 usrednjavanja i rezultati tačnosti, preciznosti i odziva prikazani su u tabeli 4.

Tabela 4. Tačnost, preciznost i odziv kod subjekata A i B pojedinačno i kod subjekata A i B zajedno kod CNN

Subjekat	Tačnost	Preciznost	Odziv
A	92.7%	95.1%	71.7%
B	94.1%	95.2%	68.7%
A i B	88.6%	90.2%	66.4%

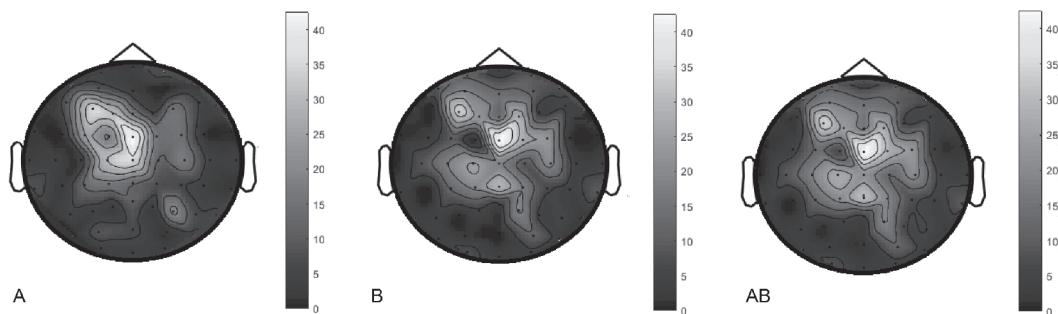
Za razliku od ostalih metoda kod konvolucionih neuronskih mreža nije primećeno naglo smanjenje bilo koje od 3 zadate metrike.

## Detekcija slova

### Klasifikator zasnovan na principu oštrog histerezisa

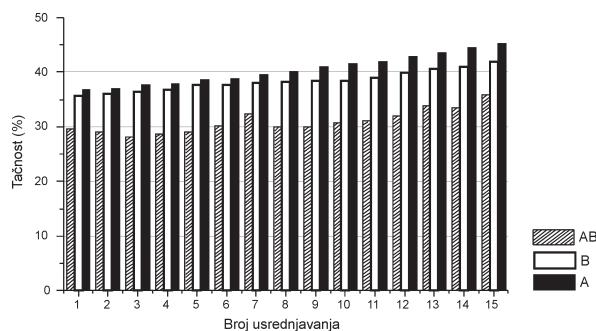
Primenivši prethodno opisani algoritam za detekciju slova, izračunava se tačnost detekcije slova za svaki kanal za sve kombinacije podataka. Vektor pomoću kojeg je vršena klasifikacija slova, je izlaz klasifikatora za detekciju P300 signala na 15 usrednjavanja. Dobijeni rezultati topografski su prikazani rezultati na slici 13.

Na osnovu ovih rezultata vidi se da se kod svih ljudi ne aktivira isti deo mozga za ovaj problem iako se u oba slučaja kao optimalna elektroda pokaže  $FC_z$ . Uvezvi elektrodu  $FC_z$  kao elektrodu na kojoj se očekuje najveća tačnost, ispitana je zavisnost tačnosti detektovanja slova od broja usrednjavanja. Rezultati su prikazani na slici 14. Na istoj elektrodi očekuje se da tačnost bude najveća bez obzira na broj usrednjavanja.



Slika 13. Klasifikator sa principom oštrog histerezisa: topografski prikaz tačnosti detektovanja slova kod subjekta A, subjekta B i oba subjekta zajedno (AB)

Figure 13. Treshold: topoplot of accuracy of detection of the letters in subject A, subject B and both subjects A and B (AB)



Slika 14. Zavisnost tačnosti detekcije slova od broja usrednjavanja kod klasifikatora sa oštrim histerezisom

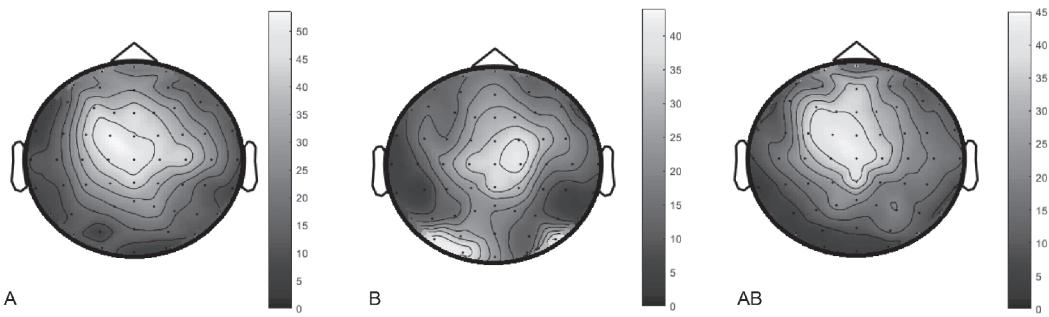
Figure 14. Dependence of the accuracy in detecting letters with threshold

## Pearsonov korelacioni metod

Mereći tačnost detektovanja slova pomoću Pearsonovog korelacionog metoda, dobijeni su rezultati koji su topografski prikazani na slici 15.

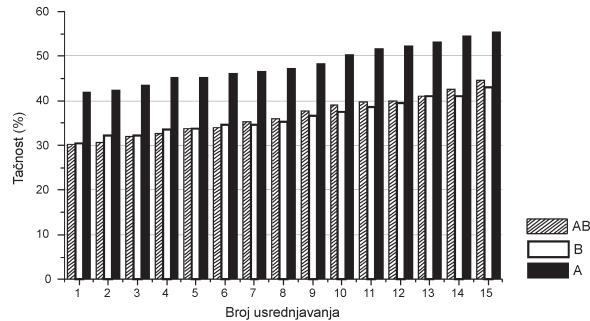
Najveća tačnost prepoznavanja slova je na 15 usrednjavanja i ona kod subjekta A iznosi 44% kod subjekta B 41%, a kod subjekata A i B zajedno 32%. Primećen je sličan trend kao kod detekcije P300 signala, tj. da tačnost prepoznavanja slova raste kako raste broj usrednjjenih signala, što je i очekivano, jer klasifikator bolje radi kako je odnos signal-šum veći. Takođe, tačnosti detektovanja signala kod osobe A i kod osobe B su slične – naime, njihove tačnosti razliku je od 1% do 4%, ali kod osoba A i B zajedno tačnost odstupa dosta u odnosu na osobe A i B, od 8% do 13%.

Na osnovu rezultata sa slika 15-A i 15-B može se zaključiti da tačnost ovog metoda dosta zavisi od subjekta do subjekta, pošto se kod subjekta A velika tačnost javlja na elektrodama koje su skoncentrisane oko temenog režnja a kod osobe B se velika tačnost javlja na elektrodama koje su skoncentrisane i oko temenog reznja ali i oko čeonog režnja. Kombinujući podatke osoba A i B dobijeno je opet da je najveća tačnost kod temenog režnja, ali se veća tačnost nego na ostatku glave javlja na čeonom režnju. Ovde se mogu uočiti delovi rezultata prikazanih na slikama 15-A i 15-B. Najveća tačnost primećena je na 15 usrednjavanja, i ona kod osobe A iznosi



Slika 15. Klasifikator sa principom oštrog histerezisa: topografski prikaz tačnosti detektovanja slova kod subjekta A, subjekta B i oba subjekta zajedno (AB)

Figure 15. Treshold: topoplot of accuracy of detection of the letters in subject A, subject B and both subjects A and B



Slika 16. Zavisnosti tačnosti detekcije slova od broja usrednjavanja kod PCM

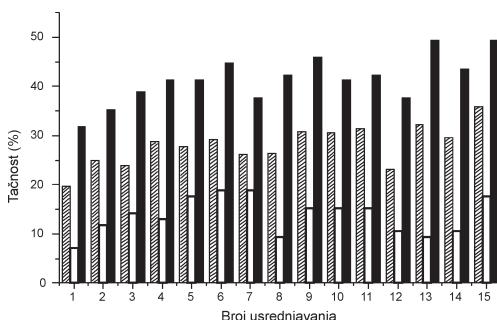
Figure 16. Dependance of the accuracy in detecting letters with PCM

55%, a kod osobe B 42%, dok je kod rezultata sa podacima osoba A i B zajedno 44%.

Na osnovu grafika na slici 16 primećuje se da u sva tri slučaja tačnost detektovanja slova raste sa brojem usrednjavanja. Samim tim uočava se da broj usrednjavanja pozitivno utiče na tačnost.

### Mašine sa vektorima podrške

Na slici 17 prikazani su rezultati prepoznavanja slova kod subjekata A i B. Kod subjekta A primećuje se da će tačnost rasti kako broj usrednjavanja bude rastao, ali postoje slučajevi koji ne prate ovaj trend. Za razliku od toga kod subjekta B ovaj rast se ne može uočiti. Čak su rezultati bolji na 5 i 6



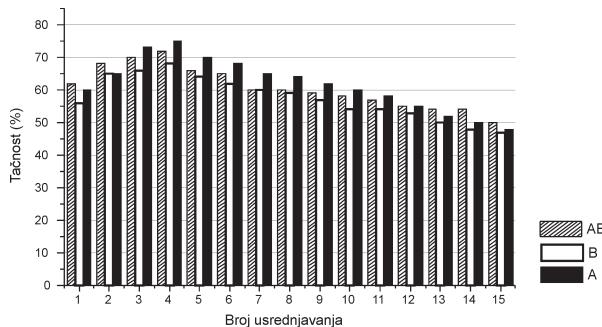
Slika 17. Zavisnost tačnosti detekcije slova od broja usrednjavanja kod SVM

Figure 17. Dependance of the accuracy in detecting letters with SVM

usrednjavanja nego na 15. Ovde se jasno vidi problem da će SVM da dosta utiče od ispitanika do ispitanika. Sličan trend može se primetiti i kod subjekata A i B zajedno. Najveća tačnost kod subjekta A je 50%, kod subjekta B 18%, a kod subjekata A i B zajedno 36%.

### Kovolacione neuronske mreže

Dobivši rezultate detekcije P300 signala izvršena je klasifikacija slova. Rezultati ove klasifikacije prikazani su na slici 18.



Slika 18. Zavisnosti tačnosti detekcije slova od broja usrednjavanja kod CNN klasifikatora

Figure 18. Dependance of the accuracy in detecting letters with CNN

Kao i na graficima koji pokazuju tačnost detektovanja P300 signala supremum funkcija nalazi se na 4 usrednjavanja. Ovakav trend primećen je i kod detekcije signala. Kao i kod detekcije signala, pretpostavlja se da metrike opadaju posle 4 usrednjavanja jer konvolucionna mreža koja ima dosta slobodnih parametara počinje da ima sve manje primera na kojima se uči i testira, te je i ovde ovakav rezultat očekivan. Najveća tačnost dobijena je na 4 usrednjavanja i ona kod subjekta A iznosi 75% kod subjekta B 68% a kod subjekata A i B zajedno 72%.

### Zaključak

U tabelama 5–7 prikazani su tačnost, preciznost i odziv detektovanja P300 signala za sve metode za subjekte A, B i AB respektivno. Kao krajnji rezultat koji je upisan u tabele uzeta je najveća vrednost koja je dobijena u nekom od 15 usrednjavanja.

Tabela 5. Tačnost prepoznavanja P300 signala kod subjekata A i B pojedinačno i kod subjekata A i B zajedno

Subjekat	Metod			
	Threshold	PCM	SVM	CNN
A	59%	78%	100%	93%
B	55%	62%	86%	88%
A i B	52%	64%	95%	89%

Tabela 6. Preciznost prepoznavanja P300 signala kod subjekata A i B pojedinačno i kod subjekata A i B zajedno

Subjekat	Metod			
	Threshold	PCM	SVM	CNN
A	41%	50%	96%	95%
B	32%	32%	80%	95%
A i B	32%	36%	93%	90%

Tabela 7. Odziv prepoznavanja P300 signala kod subjekata A i B pojedinačno i kod subjekata A i B zajedno

Subjekat	Metod			
	Threshold	PCM	SVM	CNN
A	56%	67%	92%	72%
B	52%	52%	72%	69%
A i B	51%	63%	78%	66%

U sve tri tabele može se primetiti korelacija između ovih metrika. Najveću tačnost, preciznost i odziv ima SVM, zatim CNN, pa PCM i najslabije performanse pokazao je klasifikator sa oštrim histerzisom. Kod thresholda vidi se da se izabrane metrike razlikuju 4–9% u zavisnosti od subjekta i da spajanjem ova dva subjekta tačnost, preciznost i odziv opadaju. Sličan trend primećuje se i kod CNN-a, kod koga se metrike takođe razlikuju 0–5%. Kod ostalih metoda ovako mala odstupanja nisu primećena. Kod SVM-a odstupanja se razlikuju 14–20% a kod PCM-a 13–18%. Ovim se dokazuje pretpostavka da će CNN biti invarijantna na starost u odnosu na SVM. Takođe tačnost, preciznost i odziv svih metoda su bili veći od tačnosti, odziva i preciznosti klasifikatora sa oštrim histerezisom, čime je dokazana hipoteza da će pomenuti klasifikator davati najlošije rezultate. Takođe metode zasnovane na mašinskom učenju imale su veću tačnost od PCM, što je takođe bila naša hipoteza.

Tabela 8. Tačnost prepoznavanja slova kod subjekata A i B pojedinačno i kod subjekata A i B zajedno

Subjekat	Metod			
	Threshold	PCM	SVM	CNN
A	44%	55%	50%	75%
B	41%	42%	19%	68%
A i B	32%	44%	36%	72%

U tabeli 8 prikazana je tačnost detektovanja slova za subjekte A, B i AB respektivno. Kao krajnji rezultat koji je upisan u tabele uzeta je najveća vrednost koja je dobijena u nekom od 15 usrednjavanja

Kod detekcije slova primećuje se slična pravilnost kao kod detekcije signala. Naime tačnosti kod klasifikatora sa oštrim histerzisom i CNN razlikuju se od subjekta za 3% i 7% respektivno. Kod PCM ova razlika iznosi 13%, a kod SVM 31%. Naime, ovde SVM ne pokazuje dobre performanse za prepoznavanje slova kao što je to slučaj kod detektovanja signala. Prva hipoteza da će klasifikator sa oštrim histerezisom pokazati najslabije rezultate nije tačna, jer je lošije rezultate pokazao SVM. Hipoteza 2, da će metode zasnovane na mašinskom učenju pokazivati bolje performanse od ostalih metoda je polovično tačna, jer je CNN pokazao bolje, a SVM lošije rezultate. Time je ujedno potvrđena hipoteza 3 da će CNN biti uspešniji od SVM. Lošiji rezultati SVM od klasičnih metoda mogu se objasniti činjenicom da u referentnom radu (Farwell i Donchin 1988) nije korišćen isti klasifikator kao u našem radu. Prepostavlja se da bismo implementiranjem takvog klasifikatora, mogli da dokažemo hipoteze koje sada nisu dokazane.

Zaključuje se da će najbolje performanse za detekciju signala pokazati SVM, ali da on sa klasifikatorom koji je implementiran neće dati i najbolje performanse za detekciju slova.

Hipoteza 1 koja kaže da će klasifikator sa oštrim histerezisom pokazivati lošije performanse od ostalih dokazana je za detekciju signala, ali za klasifikaciju slova ova hipoteza nije dokazana.

U referentnom radu (Farwell i Donchin 1988) klasifikator slova je klasifikator glasanja. Tačnije, ako je signal detektovan dodamo glas tom stimulusu i tako za sve stimuluse jednog slova. Posle toga vidimo koja kolona i koji red imaju najviše glasova i tako odredimo slovo. U ovom radu, pokušana je implementacija klasifikatora koji neće da prima binarni ulaz već neki realni broj koji će govoriti koliko se tom signalu „veruje”. Pošto je ovakav klasifikator pokazao loše rezultate prepostavlja se da klasifikator kom se „veruje” nije dobra ideja.

Prepostavlja se da bi se hipoteze koje nisu dokazane mogle dokazati implementacijom klasifikatora sa „glasanjem”. Ovim bi mogli da se dobiju isti rezultati prepoznavanja slova kao u referentnom radu (Farwell i Donchin 1988) koji iznosi oko 90%. Dalje napredovanje implementiranog sistema može takođe da se razvija u pravcu da bude sposoban za rad u realnom vremenu.

**Zahvalnost.** Veliku zahvalnost dugujemo profesoru Elektrotehničkog fakulteta u Beogradu, dr. Andreju Saviću, za pomoć koju nam je pružio u toku izrade projekta.

## Literatura

- Cecotti H., Graser A. 2011. Convolutional neural networks for p300 detection with application to brain-computer interfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **33** (3): 433.
- Citi L., Poli R., Cinel C. 2010. Documenting, modelling and exploiting P300 amplitude changes due to variable target delays in Donchin's speller. *Journal of Neural Engineering*, **7**: 056006.
- Cortes C., Vapnik V. 1995. Support-vector networks. *Machine Learning*, **20** (3): 273.
- Dinteren R. van, Arns M., Jongsma M., Kessels R. 2014. P300 Development across the Lifespan: A Systematic Review and Meta-Analysis. *PLoS ONE*, **9** (2): e87347.
- Farwell L., Donchin E. 1988. Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and Clinical Neurophysiology*, **70** (6): 510.
- Hodgin A. L., Huxley A. F. 1952. A quantitative description of membrane current and its application to conduction and excitation in nerve. *Journal of Physiology*, **117**: 500.
- Krusienski D., Sellers E., Cabestaing F., Bayoudh S., McFarland D., Vaughan T., Wolpaw J. 2006. A comparison of classification techniques for the P300 Speller. *Journal of Neural Engineering*, **3** (4): 299.
- Linden D. E. J. 2005. The P300: Where in the brain is it produced and what does it tell us? *The Neuroscientist*, **11** (6): 563.
- Onishi A., Zhang Y., Zhao Q., Cichocki A. 2011. Fast and reliable P300-based BCI with facial images. In *Proceedings of the 5th International Brain-Computer Interface Conference 2011*, str. 192–195.
- Sharbrough F., Chatrian G-E., Lesser R. P., Lüders H., Nuwer M., Picton T. W. 1991. American Electroencephalographic Society Guidelines for Standard Electrode Position Nomenclature. *Journal of Clinical Neurophysiology*, **8**: 200.
- SMD (Segen's Medical Dictionary) 2011. Auditory association area. <http://medicaldictionary.thefreedictionary.com/auditory+association+area>.
- Webster J. G., Clark J. W. 2010. *Medical Instrumentation*. Wiley

---

*Danilo Đokić and Milomir Stefanović*

## Comparing Classical Classification Methods, Convolutional Neural Networks and Support Vector Machines in Detecting P300 Stimuli Used for the P300 Speller

The aim of this paper is to compare methods for detecting P300 signals and the application of such detectors for implementing the P300 speller. The P300 speller is a device implementing a Brain Computer Interface that should enable paralyzed people to communicate via detecting P300 stimuli. P300 evoked potential is a physiological phenomenon that occurs 300 ms after a surprising visual stimulus that is manifested as a positive deflection of lobe potentials which may be measured using an EEG device (Figure 1). The exciter element of the device is the monitor where the matrix of letters (Figure 5) is displayed. Rows and columns of the matrix are intensified at random, and the intensification is detected via recognizing the P300 stimulus which is its consequence. An EEG sample of the duration of one second after the intensification is called an epoch. We used a database of signals used on the BCI-III competition which consists of two subjects, each with 180 recordings for a period of 32 seconds, a total of 5760 epochs. Before extracting the epochs from the signal, it was conditioned by applying the band pass filter in the frequency range 0.1–30 Hz (Figure 4), and the signal was also normalized to values between 0 and 1. The methods used for the detection were Pearson Correlation Method (PCM), Threshold detector, Support Vector Machines (SVM) and Convolutional Neural Networks (CNN). Detectors of P300 signals and individual letters were separately designed. For the purposes of training and testing classifiers, test and training sets were constructed according to the procedure shown in Figure 5. The methods used for reference have shown an accuracy of 78% for signal detection and 42% for letter detection (PCM), and 59% for the detection of signal and 44% for the detection of the letters (Threshold detector). For the detection of signals, the highest accuracy was obtained using SVM (96%), and for the detection of letters, the highest accuracy was obtained using CNN (75%).

