

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 2103

**RJEŠAVANJE KLASIFIKACIJSKIH PROBLEMA IZ
SNIMAKA ELEKTROENCEFALOGRAMA KOD SUČELJA
IZMEĐU MOZGA I RAČUNALA**

Darin Dašić

Zagreb, lipanj 2020.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 2103

**RJEŠAVANJE KLASIFIKACIJSKIH PROBLEMA IZ
SNIMAKA ELEKTROENCEFALOGRAMA KOD SUČELJA
IZMEĐU MOZGA I RAČUNALA**

Darin Dašić

Zagreb, lipanj 2020.

**SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA**

Zagreb, 13. ožujka 2020.

DIPLOMSKI ZADATAK br. 2103

Pristupnik: **Darin Dašić (0036485752)**

Studij: Računarstvo

Profil: Računarska znanost

Mentor: izv. prof. dr. sc. Alan Jović

Zadatak: **Rješavanje klasifikacijskih problema iz snimaka elektroencefalograma kod sučelja između mozga i računala**

Opis zadatka:

Sučelje između mozga i računala (engl. brain-computer interface, dalje: BCI) naziv je za računalni sustav koji prikuplja i analizira moždane signale kako bi ih pretvorio u upravljačke signale za akciju koju korisnik zamišlja da će napraviti. Za BCI se danas koristi nekoliko pristupa, a jedan od najčešćih je primjena površinske elektroencefalografije. Pritom, na temelju signala elektroencefalograma (EEG), sustav rasudiće o izboru ciljne akcije koju je potrebno ostvariti. Budući da preslikavanje EEG signala u ciljnu akciju nije jednostavno rješivo, u ovom području koriste se tehnike računalnog izlučivanja značajki iz EEG-a te se primjenjuju statistički postupci i postupci strojnog učenja za uspješnu klasifikaciju ciljnih akcija. U ovom diplomskom radu potrebno je razviti programski sustav koji će analizirati EEG signale s ciljem rješavanja klasifikacijskih problema kod sučelja između mozga i čovjeka. U radu se trebaju koristiti snimke EEG-a o BCI-u koje su slobodno dostupne iz internetskih baza podataka (npr. PhysioNet, neki međunarodni izazov i sl.). Programski sustav treba podržati učitavanje podataka, izlučivanje značajki te primjenu jedne ili više metoda strojnog učenja, uključujući dubokih neuronskih mreža, s ciljem postizanja što veće uspješnosti na odabranom problemu. Zbog očekivane velike količine podataka za analizu i težine problema u ovom području, programski sustav potrebno je vrednovati i pustiti u rad na otvorenoj platformi u oblaku po izboru.

Rok za predaju rada: 30. lipnja 2020.

Sadržaj

| | |
|--|----|
| Uvod | 1 |
| 1. Mozak i elektroencefalografija..... | 2 |
| 1.1. Mozak | 2 |
| 1.2. Elektroencefalografija | 4 |
| 2. Sučelje između računala i mozga | 9 |
| 2.1. Opis općih značajki sučelja | 9 |
| 2.2. Istraživanja o sustavima BCI..... | 11 |
| 3. Podaci i metode | 14 |
| 3.1. Podaci | 14 |
| 3.1.1. Negativnost povezana s pogreškom (ERN)..... | 14 |
| 3.1.2. Glazbeni ERP | 15 |
| 3.2. Metode | 17 |
| 3.2.1. Predobrada podataka..... | 17 |
| 3.2.2. Klasifikacija..... | 18 |
| 3.2.3. Korištena arhitektura | 23 |
| 3.2.4. Optimizacija..... | 24 |
| 3.2.5. Vrednovanje klasifikatora..... | 24 |
| 4. Rezultati analize | 26 |
| 4.1. Analiza skupa podataka ERN | 26 |
| 4.2. Analiza glazbenog skupa podataka..... | 28 |
| 4.2.1. Binarna klasifikacija | 28 |
| 4.2.2. Klasifikacija po instrumentima..... | 30 |
| 4.2.3. Odabir instrumenta u glazbenom odsječku | 32 |
| Zaključak | 35 |
| Literatura | 36 |

| | |
|--------------|----|
| Sažetak..... | 39 |
| Summary..... | 40 |

Uvod

Sučelje između mozga i računala (engl. *brain computer interface*, dalje: BCI) analizira moždanu aktivnost te ju prevodi u naredbe za računalo. Računalo te naredbe može koristiti u različite svrhe kao što je komunikacija, interakcija s okolinom, korištenje računala, lokomocija, neuroterapija, zabava te umjetnost. Posebni interes za sustave BCI pronalazimo u medicini kako bi se osobama s neuro-motornim poteškoćama povećao njihov stupanj samostalnosti. Moždana aktivnost se najčešće prikuplja snimanjem elektroencefalografije (EEG). Sustav za snimanje signala EEG-a funkcioniра tako što se na površinu glave stavljuju elektrode koje mjere napon koji dopire do površine, a generiran je aktivnošću neurona. Sustavi za snimanje signala EEG-a često osim aktivnosti mozga bilježe i neke neželjene signale koje je potrebno ukloniti iz analize.

Kako bi koristili signale EEG-a u paradigmi sučelja mozga i računala, fokusiramo se na pojedine komponente signala koje se javljaju prilikom nekih događaja. Pregledom dijela signala EEG-a koji se temporalno nalaze na istom mjestu kao i određeni događaj, moguće je primijetiti morfološke promjene u signalu kao posebne komponente istog. Sustavi sučelja računala i mozga eksplotiraju te zavisnosti i preko njih definiraju određene naredbe.

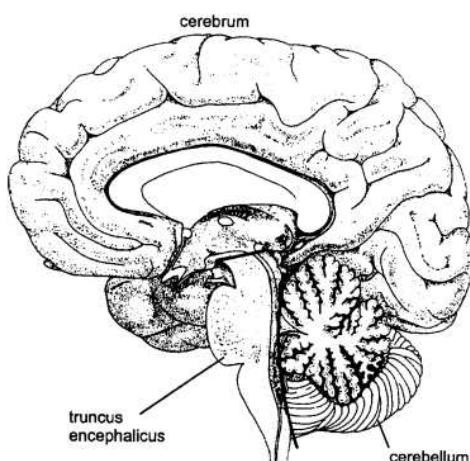
U ovom radu obradit će se detekcija tih morfoloških promjena na signalu EEG-a koristeći se konvolucijskim neuronskim mrežama. Također će se ispitati kakav ima utjecaj razlika između individualnog učenja ispitanika i prijenosa učenja na druge ispitanike na klasifikacijske performanse.

1. Mozak i elektroencefalografija

1.1. Mozak

Ljudski živčani sustav se sastoji od središnjeg i perifernog dijela. Mozak (lat. *encephalon* – doslovno „ono što je u glavi“) s kralježničnom moždinom čini središnji živčani sustav. Mozak je izravno povezan s ostatom tijela s 12 parnih moždanih živaca, te neizravno s obilnim neuronским vezama s kralježničnom moždinom.

Tri temeljna morfološka dijela mozga su moždano deblo (lat. *truncus encephalicus* ili *truncus cerebri*), mali mozak (lat. *cerebellum*) i veliki mozak (lat. *cerebrum*).



Slika 1.1 Morfologija mozga, preuzeto od [1]

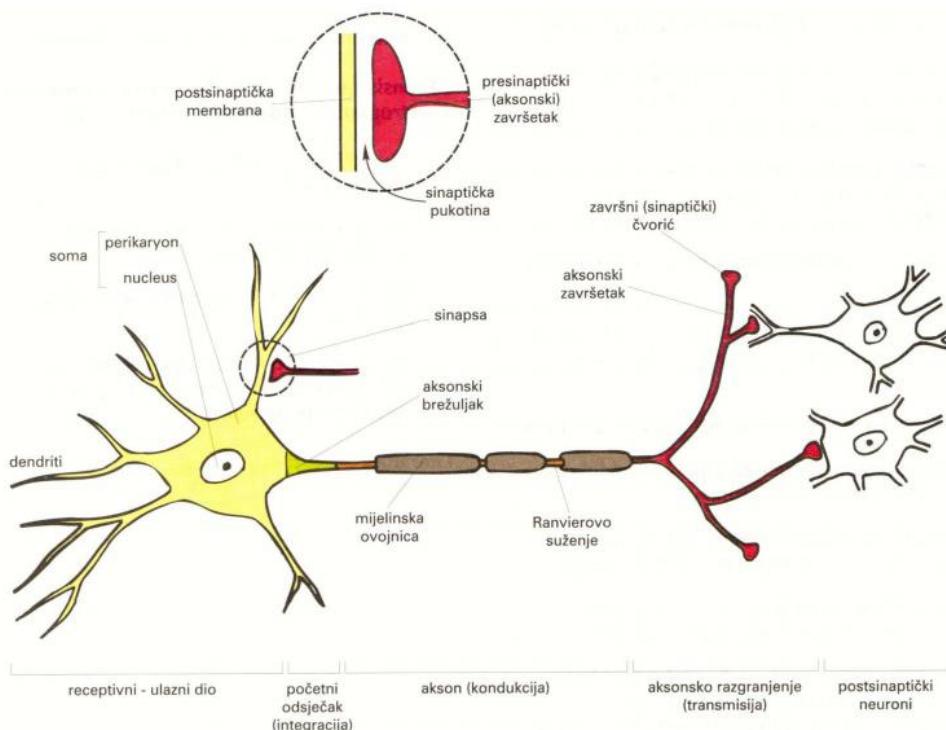
Sva tri dijela se sastoje od sive i bijele tvari. Siva tvar prekriva površinu velikog i malog mozga, dok se bijela tvar nalazi u dubini.

Dvije temeljne vrste stanica u središnjem živčanom sustavu su neuroni i glija stanice. Neuroni su živčane stanice, dok su glije potporne stanice. Neuron je glavna strukturna i funkcionalna jedinica živčanog sustava. U mozgu se nalazi oko 86 milijardi neurona, a njihova zadaća je stvaranje, primanje, vođenje te prijenos živčanih impulsa uzrokovanih raznolikim podražajima iz okoline i organizma. Zbog specifične funkcije u organizmu, morfologijom se razlikuju od ostalih stanica. Između samih neurona pronalazimo različite zadaće, stoga postoje razlike u njihovom izgledu, veličini te biokemijskim svojstvima. No, najveća se razlika manifestira u obliku veza koje tvore s drugim neuronima. Ipak, svi neuroni imaju četiri glavna morfološka dijela po kojima se razlikuju od svih ostalih stanica, a to su dendriti, soma, akson te presinaptički aksonski završetak.

Tijelo neurona ili soma sadrži jezgru stanice. Dendriti su stanične ekstenzije s mnogo grana. Kroz dendrite stanica prima većinu ulaznih informacija od drugih stanica. Dugačko živčano vlakno ili akson služi za prijenos signala kroz stanicu. Presinaptički aksonski završetci stupaju u dodir sa specijaliziranim djelićem membrane drugih neurona (postsinaptičkih) ili mišićnih, žlezdanih stanica. Tako nastaje posebni strukturno-funkcionalni spoj, sinapsa, koja je glavno mjesto interakcije između neurona te služi za prijenos signala s jednog na drugi neuron.

Svaki morfološki dio ima svoje i temeljne signalne funkcije neurona. Dendriti i soma su prijemni tj. ulazni dio neurona. Novi živčani impuls nastaje u području aksonskog brežuljka gdje počinje putovati duž aksona. Ta zona se naziva zona okidanja živčanog impulsa. Akson ima konduksijsku funkciju jer prenosi živčani impuls od mjesta nastanka do sinapse. Izlazni dio neurona je presinaptički aksonski završetak.

Kada signal dođe do spoja s drugim nevronom, sinapse, on se dalje prenosi kemijskim putem, a ne električnim. Signal dalje prenose posebne vrste molekula, neurotransimenteri. Smjer komunikacije je jednosmjeran (od presinaptičkog neurona prema postsinaptičkom nevronu).



Slika 1.2 Shema idealiziranog neurona [1]

Membrane stanica posjeduju razliku u naponu između izvanstanične i unutarstanične tekućine. Ta razlika u naponu se naziva naponom membrane stanice. Iznos tog napona je

različit u pojedinim dijelovima živčane stanice. Istraživanja su pokazala da je taj iznos najveći u aksonskom brežuljku koji se nalazi između some i aksona. Razlike u naponu postoje ovisno o stanju mirovanja i aktivnosti. U stanju mirovanja iznos napona je rezultat različitih koncentracija iona unutar i izvan stanice. Ioni natrija i kalija najviše pridonose razlici tog napona. Koncentracija natrijevih iona je 10 puta veća na vanjskoj strani membrane, dok je koncentracija kalijevih iona 30 puta veća u unutrašnjoj strani membrane.

Membrana je nepropusna te se ponaša kao izolator, međutim ona ima mehanizme za regulaciju naboja pomoću ionskih kanala. Ionski kanali prilikom određene pobude počinju propuštati natrijeve odnosno kalijeve ione kroz membranu radi regulacije potencijala.

Tijekom aktivnog stanja neurona, javlja se zanimljiva fiziološka pojava koja se naziva akcijski potencijal. Akcijski potencijal se javlja u slučaju kada je podražaj membrane dovoljno jak, odnosno veći od određenog praga. Potencijal prilikom mirovanja iznosi -70 mV, dok se prag prelazi smanjenjem potencijala na -50 mV. U tom slučaju akcijski potencijal se javlja te napon membrane aksona rapidno raste a zatim pada duž aksona. Akcijski potencijal ima glavnu zadaću propagacije živčanog signala prema sinapsama, a samim time i prema drugim neuronima.

1.2. Elektroencefalografija

Ljudski organizam prolazi kroz cikličke promjene aktivnosti koje nazivamo bioritmima. Svaka aktivnost ima svoj period unutar kojeg se odvija. Najvažniji primjeri bioritmova su ciklusi budnosti i spavanja. Svako od tih stanja je zapravo niz stanja svijesti i stupnjeva budnosti koje su posljedica aktivnih moždanih procesa. Promjene stanja svijesti su praćene promjenama fizioloških procesa u moždanoj kori, što rezultira i odgovarajućim električnim aktivnostima. Tu razliku u fiziologiji mozga a time i stanje svijesti i moždanih procesa možemo zabilježiti i snimiti kao elektroencefalografske (EEG) valove, kao izazvane (evocirane) potencijale ili kao pojedinačnu aktivnost različitih vrsta neurona moždane kore i talamus. Valovi EEG-a se temelje na skupnim električnim svojstvima neurona moždane kore. Pojedinačna područja mozga imaju specifičnu vrstu neurona što se odražava preko građe, funkcije i neuronskih veza. No, neka strukturno funkcionalna obilježja su zajednička svim dijelovima moždane kore što omogućava pojavu kolektivnih svojstava velikih populacija neurona. Ključnu ulogu u stvaranju EEG valova su potencijali piramidnih neurona. Ta skupna električna svojstva bilježimo kao EEG. EEG je zapis promjena

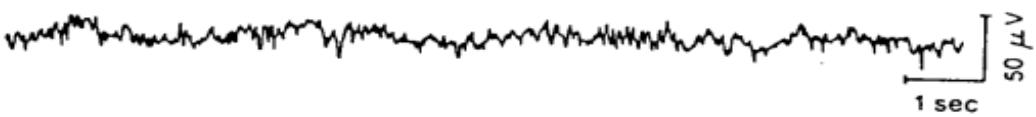
izvanstaničnog protoka struje, što je rezultat trajne i istodobne električne aktivnosti golemog broja pojedinačnih neurona. Oni putuju kao valovi kroz mozak sve do površine glave. Zato se na površini glave postavljaju elektrode koje mijere površinske potencijale. Potencijal zabilježen na elektrodi je dobar pokazatelj aktivnosti neurona neposredno ispod njega. Ono što EEG snima je odraz postsinaptičke aktivnosti, a ne akcijskih potencijala. Sinaptička aktivnost generira suptilni električni impuls poznat kao postsinaptički potencijal. Aktivnost jedne takve veze je iznimno teško pouzdano detektirati bez direktnog kontakta. Međutim, prilikom sinkronizirane aktivnosti tisuće neurona, stvara se električno polje koje se širi kroz tkivo sve do površine glave. Stoga su valovi EEG odraz neto učinaka lokalnih postsinaptičkih potencijala neurona [1].

Neuroni trajno osciliraju blizu praga aktivacijskog potencijala što ponekad rezultira okidanjem akcijskih potencijala. Ta aktivnost se naziva spontana aktivnost neurona zbog toga što se neuroni aktiviraju iako nema neke konkretne pobude.

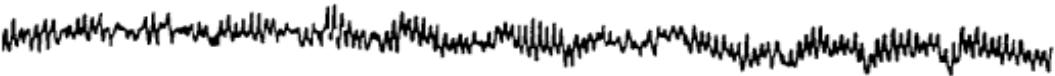
Valove EEG-a karakteriziraju njihova frekvencija, amplituda i morfologija (izgleda samog vala). Frekvencija signala EEG-a se nalazi u rasponu od 1 – 50 Hz, a amplitude od 50 – 200 μ V. Na temelju tih karakteristika prepoznajemo karakteristične valove koji nam ukazuju na različita stanja uma.

- Alfa valovi (Bergov ritam) odlikuju se frekvencijom od 8 – 13 Hz. Oni ukazuju na stanje budne opuštenosti. Kada osoba ne razmišlja o nečemu konkretnom, ima zatvorene oči i leži, ovi valovi se pojačano primjećuju u zapisu EEG-a. Najveću amplitudu imaju u zatilnjom području. Koriste se prilikom biofeedback treninga te pri promatranju inhibicije i pozornosti ispitanika.
- Beta valovi imaju frekvenciju veću od 13 Hz. Ovi valovi su pokazatelj aktiviranog, desinkroniziranog EEG-a. Vežemo ih uz korištenje dijelova tijela i motoriku. Ukazuju na pojačano, budno stanje svijesti i usmjerenu pozornost.
- Delta valovi imaju frekvenciju manju od 4 Hz. Često se koriste prilikom proučavanja analize dubine sna. Jači delta ritam ukazuje na dublji san. Ovi valovi također ukazuju na pojačanu koncentraciju usmjerenu na pamćenje.
- Gama valove (30 – 50 Hz) znanstvenici asociraju s pažljivim fokusiranjem te s razmjenom informacija između pojedinih regija mozga. Snaga ovih valova raste prilikom brzih pokreta očiju.

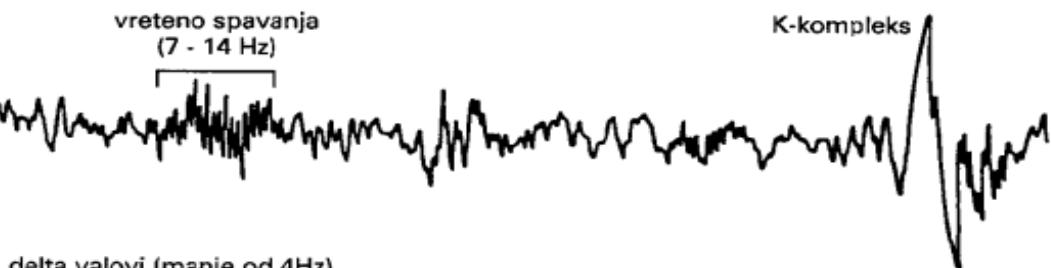
pojačana budnost - beta valovi (više od 13 Hz)



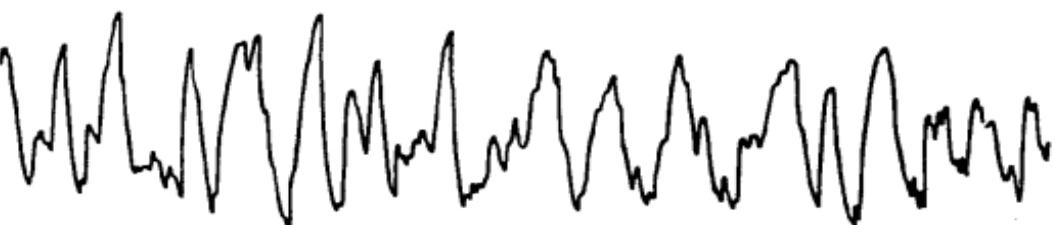
opuštena budnost i pospanost - alfa valovi (8 - 13 Hz)



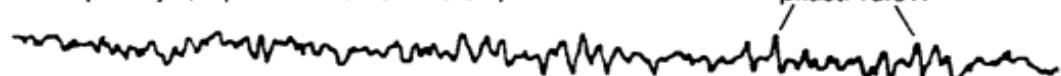
vrećeno spavanja
(7 - 14 Hz)



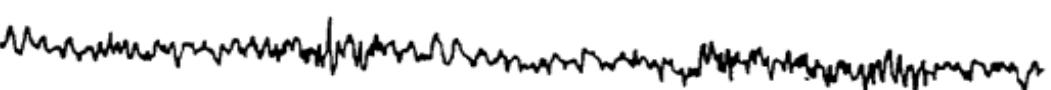
delta valovi (manje od 4Hz)



REM-spavanje (nepravilni mali brzi valovi)



theta valovi (4 - 7 Hz)



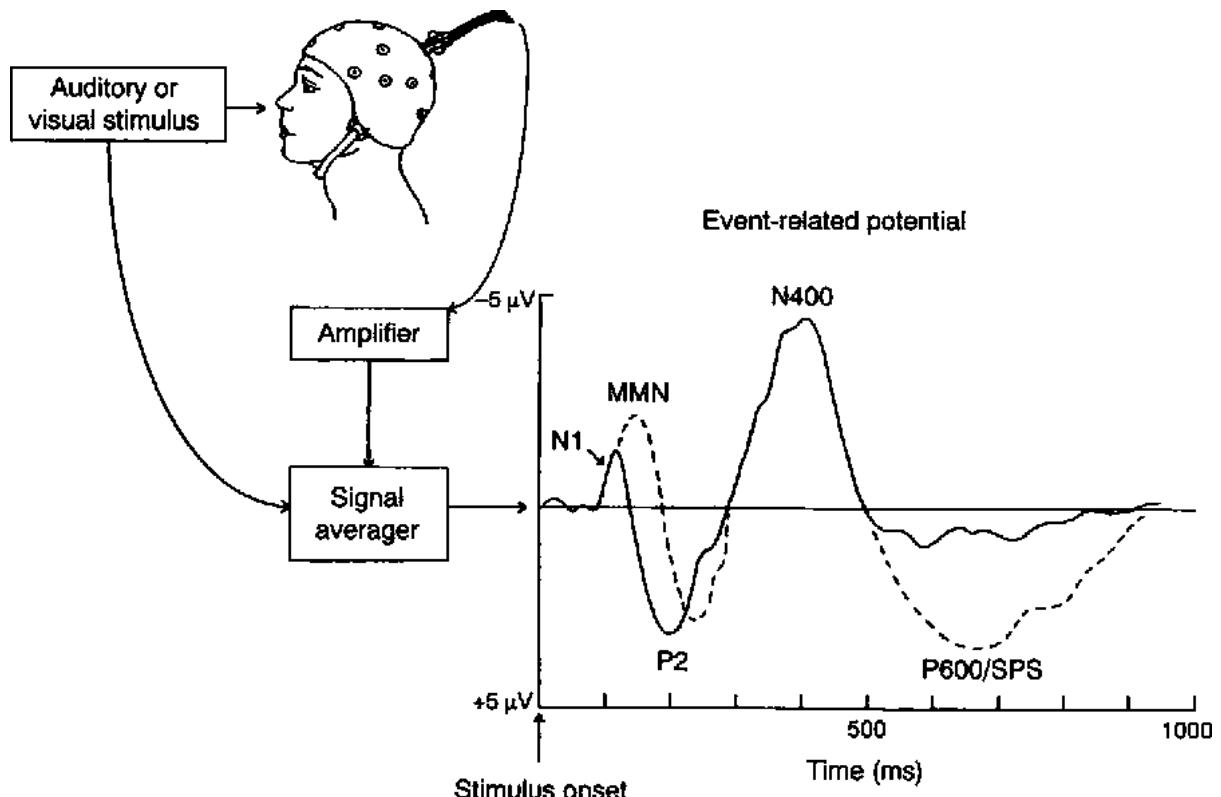
Slika 1.3 Morfologije pojedinih karakterističnih EEG valova, preuzeto [1]

Evocirani potencijal (EP) je električna promjena u mozgu koja nastaje nakon podraživanja osjetnog organa, specifičnog osjetnog puta ili jezgre talamusa. Evocirani potencijal spada u posebnu vrstu vala EEG-a, a ne u pojedinačnu aktivnost osjetnih neurona. Ovisno o izvoru EP, razlikujemo vidne evocirane potencijale (VEP), slušne evocirane potencijale (AEP) te somato-senzorne evocirane potencijale (SEP).

Slušni evocirani potencijali se sastoje od dva skupa elemenata kada promatramo EEG. Prvi skup su rezultat evociranih potencijala moždanog debla, dok je drugi skup elemenata

posljedica aktivnosti talamokortikolnog slušnog sustava i neurona slušne moždane kore. Morfološki primjećujemo u drugom dijelu pozitivne i negativne otklone.

Bitna osobina EP po kojoj se razlikuju od spontanih valova EEG-a je u tome što se javljaju točno nakon senzornog događaja te se javljaju u određenom dijelu moždane kore (ovisno o kojem se osjetu radi).

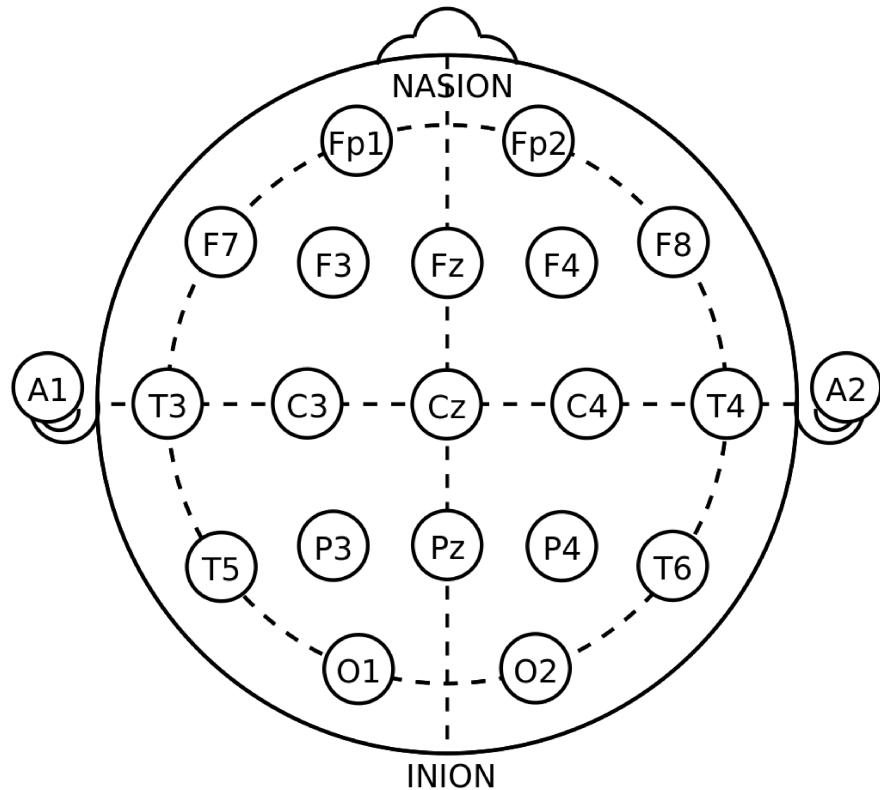


Slika 1.4 Potencijal vezan uz događaj [2]

Kada evociranim potencijalima pridružimo kontekst samog podražaja, onda oni induciraju drugačiji tip odaziva koji je vidljiv u EEG-u. Po tome se razlikuju od osjetnih evociranih potencijala i njih nazivamo potencijalima vezanima uz događaj (engl. *event related potentials*, dalje: ERP). Kontekst utječe na ERP tako da mu mijenja amplitudu. Time nam amplituda daje neke informacije uz kontekst tog podražaja. Druga karakteristika je dulja latencija nego EP što je rezultat aktivnosti asocijacijskih područja moždane kore. ERP se u medicini koristi pri istraživanju spoznajnih funkcija kao što su mišljenje, pamćenje i govor. Evocirani potencijali klinički imaju važnu ulogu u analizi osjetnih funkcija kod pacijenata koji nisu u stanju komunicirati.

Za što bolje rezultate analize moždane aktivnosti, potrebno je snimiti podatke koji što vjernije prikazuju aktivnost mozga. Radi bolje mogućnosti reprodukcije rezultata analize i standardizacije metode, 1994. godine stvorena je norma koja definira na koje pozicije na

površini glave je potrebno postaviti elektrode. Taj standard je poznat pod nazivom sustav 10-20. Elektrode se postavljaju na razmaku od 10% po dužini i 20% širini. Na glavi se nalaze 4 referentne točke, Nasion (Nz, iznad nosa), Inion (Iz, koštana izbočina na najnižoj točki lubanje) te lijeva i desna preaurikularna točka koje se nalaze anteriorno od ušiju.



Slika 1.5 Elektrode i pozicije 10-20 sustava [3]

Vertikalna linija koja spaja Nz i Iz te horizontalna linija od dvije preaurikularne točke su podijeljene na 10 jednakih sektora. Nomenklatura elektroda prati podjelu mozga te F označava čeoni, T označava sljepoočni, C označava fiktivni centralni, P označava tjemeni, dok O označava zatiljni režanj. Elektrode na desnoj hemisferi su označene parnim, dok su one na lijevoj označene neparnim brojevima. Potencijali između elektroda mogu se mjeriti monopolarno ili bipolarno. Kod monopolarnog snimanja svaki se potencijal uspoređuje s referentnom elektrodom, dok se prilikom bipolarnog snimanja potencijal računa između svake dvije elektrode koje nas zanimaju.

2. Sučelje između računala i mozga

2.1. Opći značajki sučelja

Sučelje između računala i mozga (engl. *brain computer interface* ili *brain machine interface*, BCI, BMI) je sustav koji prima podatke o moždanoj aktivnosti, obrađuje ih te pretvara u naredbe koje šalje nekom izlaznom uređaju. Ovakav uređaj omogućava komunikaciju bez ikakvih pokreta. Time se ostvaruje interakcija s okolinom preko misli.

Engleski termin „*brain computer interface*“ je prvi put koristio u svom radu [4], 1973. Dr. J. Vidal, inspiriran da pomogne osobama s invaliditetom kreirati alternativne metode komunikacije te im unaprijediti interakciju s okolinom [4].

Autori u knjizi [5] su za BCI dali sljedeću definiciju; „BCI je sustav koji mjeri aktivnost centralnog živčanog sustava te ga pretvara u umjetni izlaz koji zamjenjuje, vraća, pojačava, dopunjuje ili poboljšava prirodnu radnju i time mijenja tekuću interakciju između centralnog živčanog sustava te unutarnje ili vanjske okoline.“

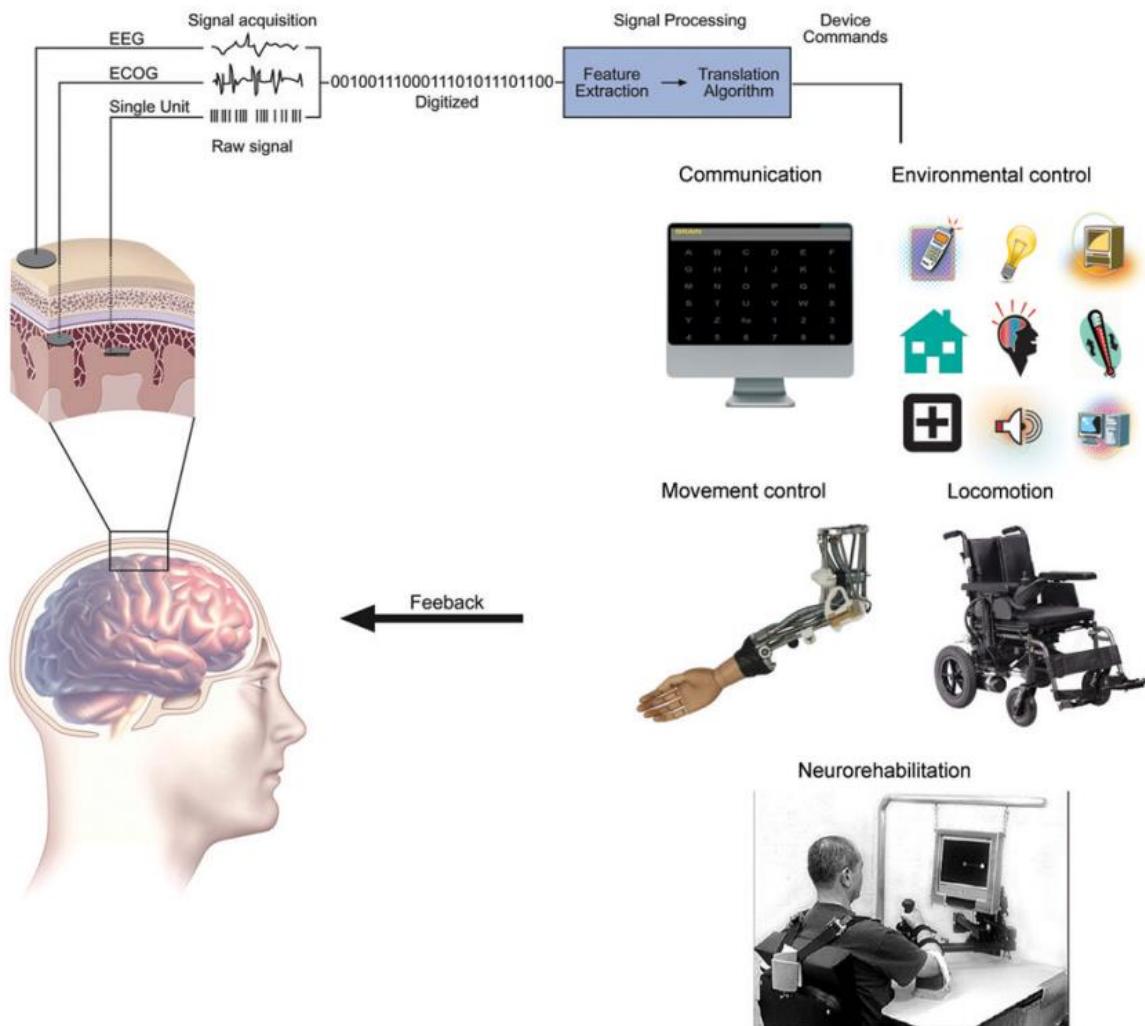
Drugačija definicija sustava BCI nalaže uvjet za BCI kojim korisnik mora imati aktivnu kontrolu intencijom. Razlike između postojanja tog uvjeta i ne postojanja dalje dijeli sustave BCI na pasivne i aktivne [6].

Sustav BCI preskače prirodne motorne izlazne kanale te koristi digitalnu obradu signala, klasifikaciju uz pomoć metoda strojnog učenja te pretvara moždane signale u naredbe. BCI radi na način da prepoznae uzorke u moždanom signalu te ih povezuje s naredbama.

Zbog toga što se naredbe izvršavaju samo na temelju moždane aktivnosti, cilj većina istraživanja o BCI je medicinska rehabilitacija. Osobe s jačim motornim poteškoćama, mogu upravljati sa sustavima BCI i time povratiti mogućnost interakcije s okolinom što zauzvrat povećava razinu samostalnosti za normalan život.

Na sustav BCI se može gledati kao na sekvencijski sustav koji se može podijeliti na svoje sastavne dijelove. Ti sastavni dijelovi su prema funkciji zaduženi za prikupljanje signala o moždanoj aktivnosti, izlučivanje značajki iz moždane aktivnosti, translaciju značajki u naredbe te izvršavanje naredbe u obliku akcije.

Za prikupljanje moždane aktivnosti najčešće se koristi neinvazivni EEG opisan u prethodnom odjeljku.



Slika 2.1 Sučelje između mozga i računala [7]

Osim prikupljanja signala EEG-a postavljanjem elektroda na površini glave, elektrode je moguće postaviti i na površinu mozga. U tom slučaju se govori o elektrokortikografiji (engl. *electrocorticography*, ECoG). ECoG spada pod invazivne metode zbog toga što je potrebno kirurškim zahvatom otvoriti lubanju (kraniotomija) kako bi se elektrode mogle postaviti na površinu mozga. Prednosti ECoG nad elektrodama postavljenim na površini glave jest u boljem omjeru signala i šuma, većoj prostornoj rezoluciji signala što u konačnici znači boljoj reprezentaciji moždane aktivnosti. Osim invazivnosti kao glavne mane, postavljene elektrode prekrivaju puno manju površinu mozga jer su ograničene površinom izloženog dijela mozga prilikom kraniotomije. Još jedan korak dalje što se tiče invazivnosti ali i rezolucije i kvalitete prikupljanja signala su moždani implantati u obliku polja mikroelektroda (engl. *microelectrode array*).

Od drugačijih načina snimanja moždane aktivnosti koriste se funkcionalna magnetna rezonancija (fMRI) te bliska infracrvena spektroskopija (engl. *near-infrared spectroscopy*, NIRS). Prema radu [24], fMRI se odlikuje visokom prostornom rezolucijom, prihvatljivom vremenskom rezolucijom, jednostavnom kalibracijom te kratkim vremenom pripreme ispitanika. Međutim, primjena je ograničena jer se ispitanik mora nalaziti u stroju za fMRI. NIRS se koristi za praćenje aktivacija pojedinih regija moždane kore, koristeći svjetlost valnih duljina u rasponu od 600 – 900 nm. Prednosti su mu neinvazivnost, jednostavnost korištenja, ekonomičnost te prenosivost [26].

Izlučivanjem značajki iz signala EEG-a, dobivamo skup značajki koje kompaktno predstavljaju važne informacije sadržane u EEG-u. Njihov cilj je minimizirati gubitak važnih informacija sadržanih u signalu, dok s druge strane smanjuju veličinu reprezentacije signala EEG-a. Značajke predstavljaju distinktna svojstva, prepoznatljivu mjeru te funkcionalnu komponentu iz segmenta jednog uzorka signala [25]. Dobre značajke trebaju biti visoko korelirane s naredbama koje pokušavaju dekodirati.

Translacija značajki u naredbe je skup metoda i funkcija kojima se iz izlučenih značajki dekodira naredba. Za tu potrebu se najviše koriste metode strojnog učenja. Za pojedine algoritme je moguće preskočiti zaseban korak izgradnje značajki jer je implicitno ugrađen u same algoritme strojnog učenja.

Nakon što je dekodirana naredba ili namjera samog ispitanika ona se realizira ovisno o namjeni sustava BCI. To može biti ulazni uređaj za upravljanje računalom kao što je pomicanje pokazivača miša, unos teksta virtualnom tipkovnicom, igra video igara, ali se može prevesti i kao izlaz za pokret protetskog ekstremiteta, govor itd.

2.2. Istraživanja o sustavima BCI

U zadnjih nekoliko godina, istraživanja na području BCI-a rastu na popularnosti. Mnoge svjetske i znanstvene organizacije su zbog toga formirane kako bi se usmjerila i poticala ova istraživanja. Tako je i pod financiranjem Europske Unije razvijen program BNCI Horizon 2020 (<http://bnci-horizon-2020.eu/project>). Cilj ovog programa nije aktivno istraživanje, već promicanje suradnje i komunikacije između svih dionika u području BCI-a. Trenutno se na spomenutoj stranici može pronaći 27 različitih skupova podataka, od kojih je jedan korišten u praktičnom dijelu ovog rada.

Vrlo važna zaklada koja promovira istraživanja u ovom području je the BCI Award Foundation. Ova zaklada je osnovana 2017. godine u Austriji te svake godine nagrađuje najznačajnije timove i njihove rade u području BCI s fondom od 6000\$.

U radu [28], autori su predstavili tretman za liječenje ovisnosti o pušenju cigareta koristeći se neurofeedbackom. Za kreiranje ovog sustava, autori su svoj protokol organizirali u dvije cjeline; konstrukcija klasifikatora obrazaca (engl. *pattern classifier construction*), koji se koristi prije samog vježbanja te gasitelj obrazaca (engl. *pattern de-activation*), koji se koristi za vrijeme neurofeedbacka. Za izgradnju klasifikatora su koristili linearni stroj potpornih vektora, dok su značajke izlučili iz vremenske i vremensko-frekvencijske domene. Rezultati su pokazali značajni kratkotrajni i dugotrajni učinak u smanjenju količine konzumacije u nekim slučajevima od čak i 38.2%.

Prošlogodišnji osvajači BCI Award nagrade su objavili svoj rad [28] u kojem su istražili upotrebu polja mikroelektroda za dekodiranje govora, kako bi povratili govor osobama s neurološkim ozljedama ili bolesti. Zanimljiva je činjenica da su implantirali dvije elektrode u područja koja se asocira uz motoriku ruka i dlanova. Međutim, rezultati su pokazali sposobnost razlučivanja između 9 fonema i tišine s točnosti od 81% u jednoj procjeni (engl. *single trial*). Za klasifikaciju su koristili značajke iz neurokodiranja [22] (engl. *neural coding*) i linearni stroj potpornih vektora kao klasifikator.

Svake godine se održavaju mnoga natjecanja u kojima natjecatelji moraju za dani problem i skup podataka razviti što bolje rješenje. Tako je prošle godine (2019.) u Portugalu, u sklopu MEDICON-a održano natjecanje sa ciljem detekcije P300 signala za identifikaciju fokusiranog objekta među ispitanicima s autističnim poremećajima. Od 10 objavljenih rada na temi natjecanja, 4 rada je ispitivalo rad konvolucijskih neuronskih mreža, dok je pobjednički tim koristio arhitekturu EEGNet-a. Isti broj rada je koristio linearnu analizu različitih (engl. *linear discriminant analysis*, LDA). Dok se od ostalih često korištenih metoda spominju strojevi potpornih vektora te višeslojni perceptron.

Za izgradnju robusnog sustava BCI, predmet mnogih istraživanja je bilo iskorištavanja komponente ErrP iz signala EEG-a. Kako je već bilo poznato da se ova komponenta javlja prilikom grešaka za koje je sam ispitanik kriv, postavlja se pitanje da li je također prisutna u EEG-u i kada je sustav BCI zaslužan za grešku. U radu [29], autori su se bavili upravo tim pitanjem, te su svojim istraživanjem potvrdili postojanje ErrP-a i kada je sustav kriv. Kao mana korištenja ErrP-a se navodi povećanje mentalnog napora za ispitanika te smanjenje brzine interakcije preko sustava BCI.

Ekstenzivni pregled radova koji se bave eksploracijom ErrP-a za kreiranje hibridnog sustava BCI je odrađen u [30]. Primjetili su da jako mali postotak istraživanja u kojemu su ispitivanja odrađena nad osobama s motornim poteškoćama koji su ciljana skupina namjene ovih sustava. Ipak, rad [31] pronađe da su obrasci ErrP-a jednaki ili jako slični kod zdravih osoba i invalida. Međutim, u slučaju primjene sustava BCI za rehabilitaciju, rezultati su suprotni. Radovi [8], [32] navode da i u slučaju točnih detekcija pogrešaka i ispravljanja istih, ispitanici su izrazili preferenciju za sustave bez detekcije ErrP-a, zbog nedovoljne dodatne vrijednosti u odnosu na dodatnu komplikaciju korištenja. U konačnici, klasifikator pozitivnih i negativnih povratnih pokušaja mora biti znatno uspješniji nego klasifikator primarne funkcije BCI-a. Tu dolazi do problema zbog neuravnoteženog omjera klase, što je u [33] probano riješiti tako da je primarni klasifikator namjerno krivo dekodirao intencije ispitanika što je u konačnici rezultiralo s više ErrP-a u povratnim sjednicama, no u tom slučaju dolazi do nepovjerenja korištenja istog sustava zbog velikog broja primarnih grešaka. Autori u [30] su primjetili da ne postoji standardizirana metoda evaluacije sustava BCI s detekcijom ErrP-a, te većina radova koristi različite metode.

Glazba je za većinu ljudi sastavni dio svakodnevnog života. Ona povezuje i okuplja ljude, budi i pojačava razne emocije u njima, te je zbog toga važna socijalna i kulturna komponenta života. Zbog ovako važne uloge u životima mnogih pojedinaca, provedena su mnoga istraživanja u kojima se glazba koristi u sustavima BCI. Glazba u sustavima BCI ima različite uloge, u nekim radovima ona se koristi kao podražaj dok je drugima ona izlaz, tj. generirana iz moždanih valova. U radu [34] je prvi put generiran zvuk na temelju Bergerovog ritma, međutim kada se priča o glazbenom dijelu, umjetnik Alvin Lucier je 1965. godine izveo djelo pod nazivom „*Music For Solo Performer*“ u kojem je uglazbio svoje moždane valove. Sinteza glazbe iz moždane aktivnosti se u [35] temelji na ekstrakciji raznih vremenskih, vremensko-frekvencijskih značajki, s naglaskom na Hjorthovu analizu, koje kasnije na temelju skupu pravila generiraju glazbu. Drugačiji pristup je u [36] istražen u kojemu ispitanici na temelju vizualno evociranog P300 signala, s ekrana biraju note koje se kasnije koriste u generiranju glazbe. Iako je vizualni ERP često korišten kao podražaj, osim u [10], glazba nije pretjerano istraživana za te svrhe.

3. Podaci i metode

3.1. Podaci

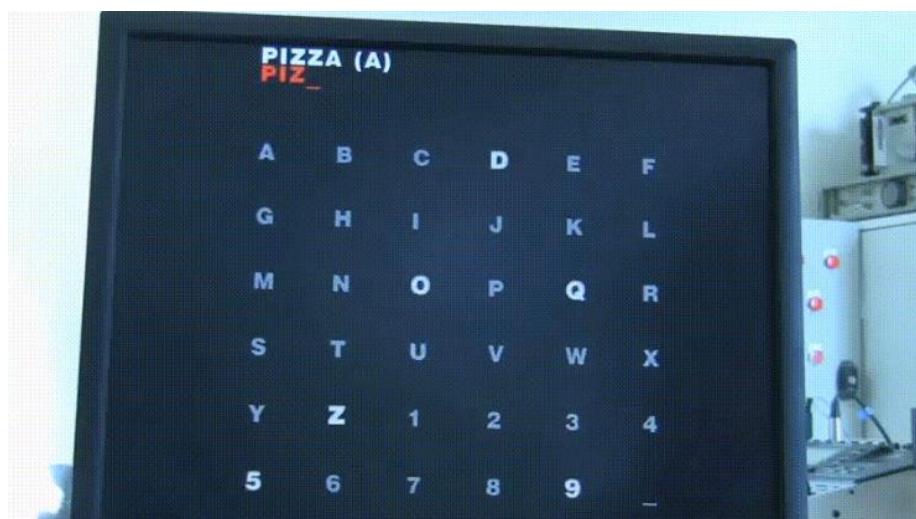
3.1.1. Negativnost povezana s pogreškom (ERN)

Negativnost povezana s pogreškom (engl. *error-related negativity*, ERN) je komponenta ERP-a. Ova vrsta moždane aktivnosti se javlja prilikom povratne sjednice (engl. *feedback session*). Prilikom povratne sjednice, komponenta ERN se javlja približno 350 ms nakon događaja, nakon koje se javlja pozitivna komponenta 500 ms od događaja.

Skup podataka u kojem se analizira ova komponenta EEG-a je izvorno sakupljen za rad [8], te je također korišten u Kaggleovom natjecanju „BCI Challenge @ NER 2015“, s koje je i skinut za daljnju analizu.

Eksperiment je bio postavljen na način da ispitanici koriste P300 sustav za recitiranje te se detekcija ERN-a koristila za poboljšanje performansa sustava.

Sustav baziran na P300 komponenti signala za recitiranje se sastoji od vizualnog podražaja te snimanju signala EEG-a ispitanika. Cilj je omogućiti osobama koje nisu u stanju kontrolirati motorički svoje tijelo. Na taj način im se omogućava komunikacija s drugim osobama te interakcija s računalom kako bi npr. mogli pretraživati internet. Sustav na ekranu prikazuje skupine slova koje se mijenjaju pravovremeno.



Slika 3.1 P300 sustav za recitiranje [9]

Svaki znak se nalazi u dvije različite skupine znakova, te prilikom koncentracije na taj znak a samim time i na te skupine znakova, EEG očitava ERP prilikom prikazivanja tih skupina. Na temelju toga, sustav može odrediti na koji znak je subjekt bio fokusiran. Međutim, greške u sustavu ili manjak koncentracije kod ispitanika dovode do pogrešno odabranih znakova. Prije konačne potvrde niza znakova, ispitaniku se prikazuje što je sustav uspio zaključiti, te se taj dio naziva sjednica povratnih informacija. U tom dijelu se na ekranu postepeno prikazuje znak po znak, te ukoliko je došlo do pogreške moguće ju je detektirati kroz komponentu ERN iz signala EEG-a. U tom slučaju krivi znak se može zamijeniti sa sljedećim najizglednijim ili nekom drugom metodom. U konačnici, sustav P300 za recitiranje s povratnom sjednicom može poboljšati svoju funkcionalnost i korisničko zadovoljstvo korištenja ovakvog sustava.

U ovom je ispitivanju sudjelovalo 26 zdravih osoba (13 žena, starosti od 20 – 37 godina, sa srednjom vrijednošću od 28.8). Svi ispitanici su imali normalan ili ispravljen vid te nisu imali iskustva s BCI paradigmom. Aktivnost mozga je snimana s 56 pasivnih Ag/AgCl EEG senzora postavljenih prema 10-20 sustavu. Signal je uzorkovan frekvencijom od 600Hz, s Ns elektrodom kao referentnom.

Skup podataka dostupan na Kaggleovoј stranici natjecanja [9] se sastoji od skupa za učenje u kojem se nalaze sve snimke od 16 ispitanika te odgovarajućim oznakama, dok je skup od 10 ispitanika zadržan kao skup za testiranje. Stoga je cilj ovog natjecanja bio izgraditi model koji dobro generalizira na signalima novih ispitanika.

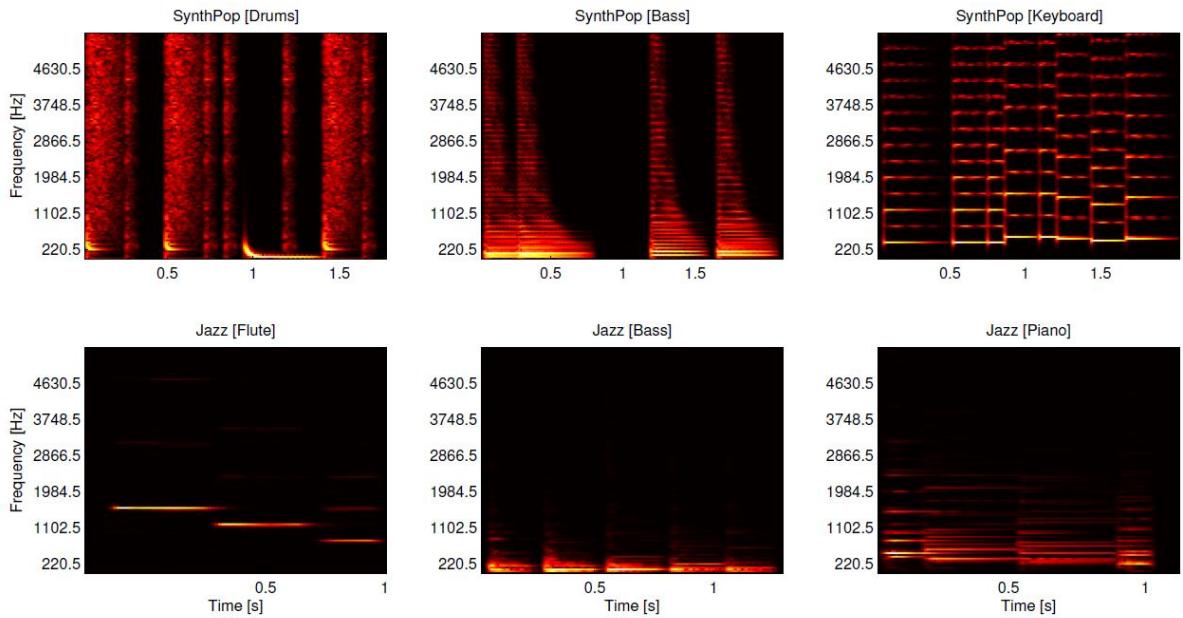
3.1.2. Glazbeni ERP

Ovaj skup podataka je skinut s lokacije BNCI HORIZON 2020 (<http://bnci-horizon-2020.eu/database/data-sets>) na kojoj se između ostalog mogu pronaći i mnogi drugi skupovi podataka vezani uz BCI paradigmu.

Podaci su izvorno sakupljeni za rad [10]. Glavni cilj istraživanja izvornih autora ovog skupa podataka je ispitati koliko je polifonijska glazba (glazba u kojoj više instrumenata svira paralelno) prikladna kao podražaj u P300 paradigmu sučelja mozga i računala. Za prikupljanje podataka u eksperimentu je sudjelovalo 11 ispitanika (7 muških i 4 ženskih), koji su slušali polifonijske glazbene isječke sastavljene od tri različita glazbena instrumenta. Svaki od tih instrumenata su ponavljali isti glazbeni uzorak uz mogućnost pojave neke devijacije, tj. uzorka drugačijeg od standardnog. U jednom trenu je moguća pojava devijacija

samo jednog instrumenta, tj. ako jedan instrument svira devijantni uzorak, druga dva sviraju standardni. Prilikom testiranja, ispitanike se zatražilo da se fokusiraju na devijacije određenog instrumenta.

Ispitanici su u eksperimentu mogli slušali četiri različite vrste glazbena isječka. Isječci su bili sljedećih tipova; Synth-pop, Jazz, Synth-pop solo i Jazz solo. Solo verzije se sastoje od jednog instrumenata odsviranih posebno iz prve dvije skupine.



Slika 3.2 Log-amplitudni spektrogram devijacija, preuzeto iz [10]

Glavna razlika između SynthPop i Jazz isječka je u tome što Jazz uzorci zvuče prirodnije, a to je postignuto ručnim naštivanjem vremena izvođenja svakog tona u standardnom uzorku. Instrumenti i njihove dionice su odabrane tako da budu što različitije jedne od drugih. To dalje rezultira boljom mogućnošću separacije pojedinih glazbenih komponenti prilikom slušanja. Za obje vrste glazbenih isječaka instrumenti su podešeni na istu razinu glasnoće.

Za snimanje signala EEG-a, korištena je aparatura s 64 elektroda Fp1-2, AF3,4,7,8, Fz, F1-10, FCz, FC1-6, FT7-8, T7-8, Cz, C1-6, TP7-8, CPz, CP1-6, Pz, P1-10, POz, PO3,4,7,8, Oz,1,2 te zadnja elektroda je zapravo EOG kanal koji prati pokrete očiju. Elektrode su postavljene prema 10-10 sistemu, referencirane prema lijevom mastoidu. Hardverski su propuštene frekvencije između 0.016 – 250 Hz te je signal izvorno uzorkovan frekvencijom od 1000 Hz, međutim skinuti podaci su dostupni u poduzorkovanoj verziji od 200 Hz.

Glavni predmet analize u ovoj studiji je mogućnost razlikovanja signala EEG-a prilikom detekcije fokusirane devijacije i nefokusirane devijacije instrumenta.

Eksperimentalni dizajn je bio sljedeći. Ispitanici su sjedili ispred ekrana te dobivali pisane i verbalne instrukcije. Zatraženi su da sjede mirno te da smanje pokrete očiju. Kako bi izazvali što veći mentalni fokusi, od njih je zatraženo da broje svaku devijaciju fokusiranog instrumenta. Prije svakog eksperimentalnog pokusa, vizualno su upućeni na koji instrument se trebaju fokusirati. Nakon toga bi odslušali standardni uzorak te devijaciju.

3.2. Metode

3.2.1. Predobrada podataka

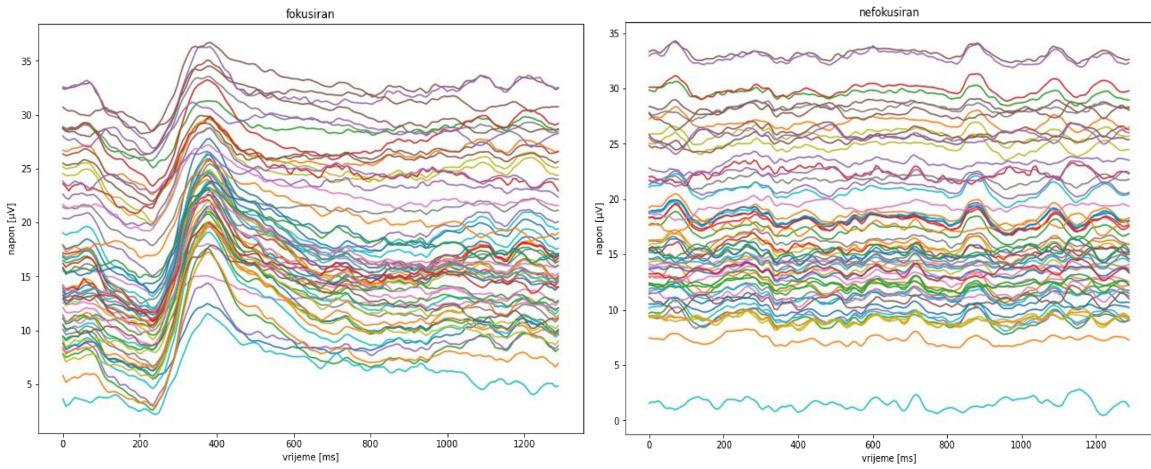
Skup podataka ERN je dostupan u frekvenciji uzorkovanja od 200 Hz. Pregledom gustoće spektralne snage jasno je vidljivo zagađenje signala utjecajem gradske mreže. Uporaba *notch* filtara kojim se uklanja određena frekvencija (u ovom slučaju 50 Hz), za sobom ostavlja neželjene distorzije na morfologiju komponenata ERP signala EEG-a. Stoga je rješenje korištenje pojasno propusnog filtera u rasponu frekvencija 1 – 40 Hz jer frekvencije veće od 40 Hertz slabo dopiru do elektroda na površini glave. Ovo filtriranje je odradeno uz korištenje zadanih vrijednosti metode `filter.filter_data` iz pythonove biblioteke mne.

Sljedeći korak je segmentacija podatke iz jednog kontinuiranog signala u epohe koje odgovaraju početcima povratnih sjednica. Prije svakog povratnog događaja, 200 ms signala je uzeto za korekciju osnovnog pravca (engl. *baseline correction*). Od tih 200 ms prije signala izračunata je srednja vrijednost te oduzeta od svake točke u slijedećem dijelu tog segmenta. Dobiveni signal od 1300 ms je poduzorkovan na frekvenciju od 128 Hz radi smanjenja dimenzionalnosti.

U skupu za učenje je odradjen korak u kojemu su odbačeni signali kod kojih je razlika između minimalne i maksimalne vrijednosti u kanalima Fp1 i Fp2 prešla prag od $100\mu\text{V}$. Također je izbačen i cijeli EOG kanal iz analize.

Za drugi skup podataka postupak predobrade je isti kao i kod prvog skupa osim što podaci nisu filtrirani od bilokakvih frekvencija jer pregledom PSD se vidi da je taj korak već odradjen.

Iz cijele analize su izbačeni glazbeni odsječci koji su označeni kao nedovršeni.



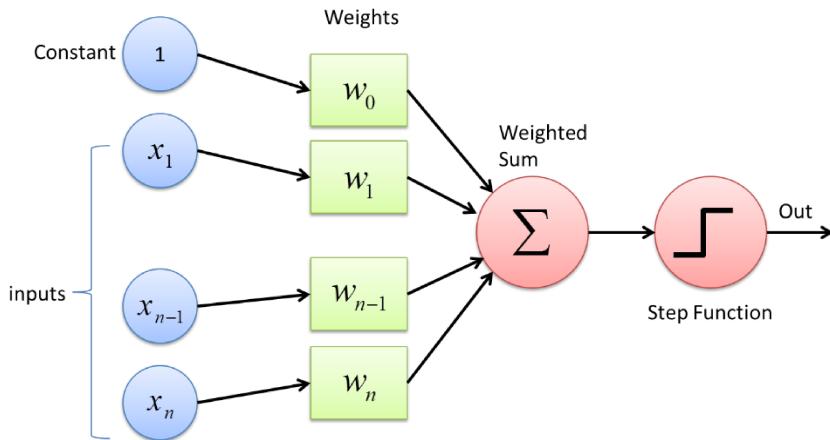
Slika 3.3 Razlika između morfologije fokusiranih i nefokusiranih devijanata u glazbenom skupu podataka za sve kanale ispitanika VPaan

3.2.2. Klasifikacija

Za izradu kvalitetnog klasifikatora signala EEG-a, potrebno je multidisciplinarno znanje u područjima obrade signala, ekstrakcije značajki te neurologije. Međutim, uz nedavne velike napretke u području dubokog učenja, konkretno umjetnih neuronskih mreža potrebe za dugogodišnjim iskustvom za predobradu signala te izgradnju kvalitetnih značajki nisu uvjet za konstrukciju kvalitetnog klasifikatora, a time i sustava BCI. Autori rada [22] su ekstenzivnom analizom 154 znanstvenih radova izdanih između 2010. i 2018. koji se bave tematikom dubokog učenja i EEG-om, zaključili da je 40% studija koristilo konvolucijske neuronske mreže (convolutional neural network, CNN), dok ih je 13% koristilo povratne neuronske mreže (recurrent neural network, RNN) najčešće koristeći između 3–10 slojeva. Druga važna spoznaja iz njihovog istraživanja je napredak od 5.4% u performansama nasuprot tradicionalnih metoda, ali uz naznaku da većina radova pati od slabe reproducibilnosti rezultata.

Umjetne neuronske mreže predstavljaju skupinu modela strojnog učenja čiji su algoritmi i struktura inspirirani ljudskim mozgom. Kao što je navedeno u poglavljju 2, neuron prima informacije od susjednih neurona s kojima je povezan. Nakon što primi signale, on njih zbraja te reagira na neto sumu svih ulaza, a ne na pojedinačne signale. Ta neto suma mora biti veća od nekog praga te u tom slučaju slijedi njegova reakcija. Analogno tome dizajniran je umjetni neuron. On također prima ulazne podatke od svojih susjednih 'neurona' s kojima je povezan. Ti susjedni podaci su zapravo ulazne značajke s kojima učimo model. Svaki ulaz

se množi s njegovom odgovarajućom težinom i na kraju zbraja sa svim ostalim ulazima. Tako se dobiva iznos koji je težinska suma svih veza. Taj iznos se 'aktivira' pomoću aktivacijske funkcije. Takav najjednostavniji model predstavlja perceptron koji se koristi za binarnu klasifikaciju gdje aktivacijska funkcija preslikava izlaz u realni broj između 0 i 1 (ili -1 i 1).



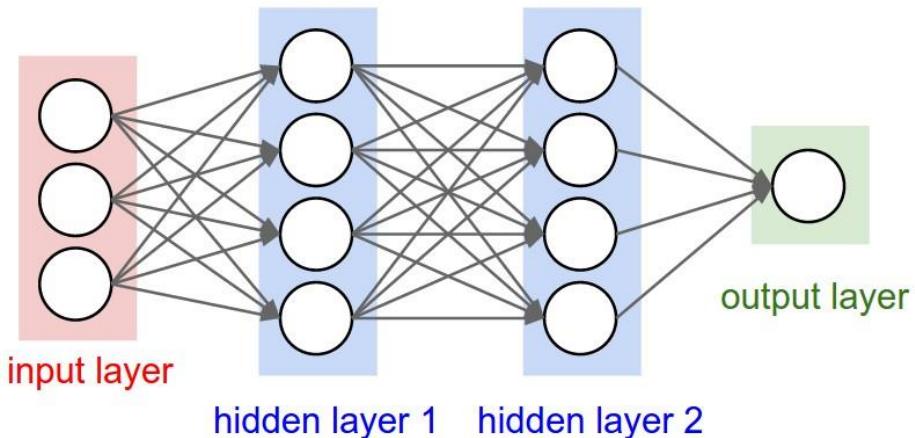
Slika 3.4 Perceptron [11]

Opisan model perceptrona nad kojim je objašnjen jednostavan umjetni neuron je zapravo pojednostavljena verzija neuronske mreže koja se sastoji od samo jednog sloja.

Slaganjem više slojeva perceptrona dobivamo klasičnu umjetnu neuronsku mrežu, a ona se ponekad i zove višeslojni perceptron (engl. *multi-layer perceptron*, MLP). Drugi nazivi su potpuno povezani model (engl. *fully connected*) ili unaprijedna umjetna neuronska mreža. Mreža ovog oblika predstavlja matematički model koji se sastoji od većeg broja jednostavnih funkcija koje su međusobno umrežene. Takvim ulančanim funkcijama ulazni podaci se nelinearno transformiraju što omogućava kreiranje značajki koje nije moguće plitkim modelima. Snaga neuronskih mreža je konstrukcija značajki slojevito, nelinearnim transformacijama.

Kod unaprijednih neuronskih mreža tok podataka je iz ulaza prema izlazu, bez petlji. Zato se operacije koje se odvijaju mogu predstaviti kompozicijom jednostavnih funkcija. Oblik ulaza i izlaza je točno definiran podacima s kojima radimo, dok slojevi između definiraju koliko je mreža duboka. Ti slojevi između se nazivaju skriveni slojevi. U svakom skrivenom sloju potrebno je definirati i broj neurona koji se nalazi u tom sloju. Na slici 3.4 je moguće vidjeti ustroj ovakve mreže. Konvolucijske neuronske mreže (engl. *convolutional neural networks*, CNN) su trenutno najpopularnija verzija neuronskih mreža. One su zasigurno

jedne od najuspješnijih arhitektura dubokog učenja, koje su sa svojim uspjehom pokrenuli revoluciju u primjenama dubokih modela.



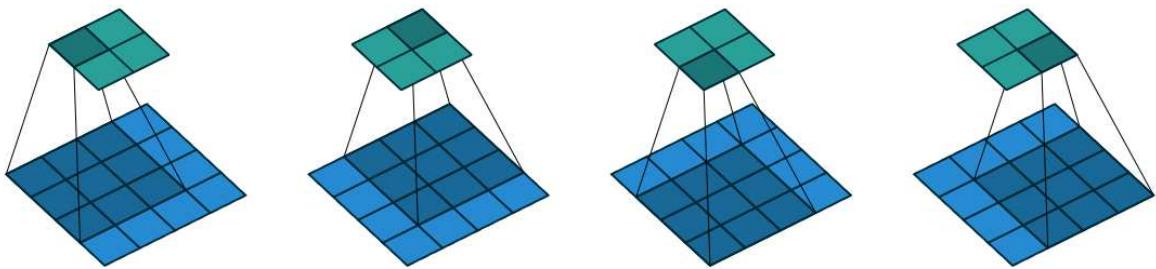
Slika 3.5 Slojevi u potpuno povezanoj neuronskoj mreži [12]

Iako je njihov uspjeh relativno nov, one su osmišljene krajem 20. stoljeća za rješavanje problema prepoznavanja znakova [13]. Konvolucijske neuronske mreže su specijalizirane za rad s podacima s topologijom rešetke, tj. oblik strukture je definiran relacijom susjedstva [14]. Zbog toga ove arhitekture mogu graditi dobre značajke za tipove podataka kao što su vremenski sljedovi, slike ili tekst. Ovi podaci međusobno dijele slijedeća svojstva:

- Pohranjeni su u obliku višedimenzionalnog polja
- Sadrže jednu ili više osi za koju je poredak važan (visina i širina slike, vrijeme u signalu EEG-a)
- Jedna os predstavlja različite kanale podataka (boja slike, lijevi ili desni audio kanal kod glazbenih datoteka, elektroda u signalu EEG-a)

U potpuno povezanoj neuronskoj mreži ova svojstva i njihove relacije nisu iskorištene, jer se ne uzima u obzir lokalitet i ustroj pojedinih značajki te zbog toga nije moguće iskoristiti vremenske ili prostorne informacije iz podataka. Zbog tih nedostataka kod afine transformacije značajki dolazimo do nove operacije – diskretne konvolucije.

Konvolucijske neuronske mreže se razlikuju od klasične neuronske mreže po tome što sadrži barem jedan konvolucijski sloj. U konvolucijskom sloju podatke transformiramo operacijom diskretne konvolucije. Diskretna konvolucija je linearna transformacija koja čuva ustroj značajki. Prednost konvolucije se očituje i u činjenici da je rijetka (samo neki ulazi pridonose izlazu) te da se parametri ponovno koriste na svim dijelovima ulaza. To u konačnici znači puno manji broj parametara za učenje mreže te bržu evaluaciju.



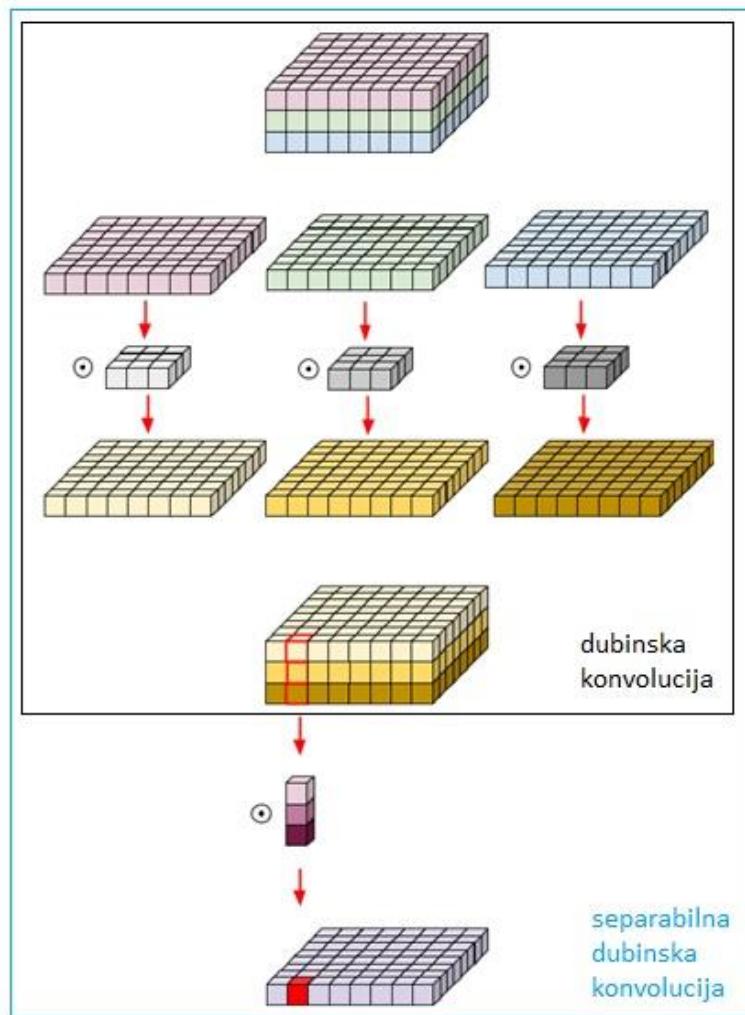
Slika 3.6 Operacija konvolucije [15]

Na slici 3.5 svijetlo plavom bojom je predstavljena ulazna mapa značajki. U ovom primjeru postoji samo jedna mapa, međutim može ih biti i više. Tamno plavom bojom je predstavljena konvolucijska jezgra. Ona sadrži iste težine prolaskom kroz sva područja ulazne mape značajki. Jezgra prolazi kroz sve lokacije ulaza te množi produkt između preklapajućih elemenata dijela ulaznih značajki i jezgre. Na kraju dobivamo zelenu mapu značajki operacijom tamno plave jezgre nad svjetloplavim ulazom. Nad istim ulazom može se koristiti veći broj jezgri kako bismo dobili više izlaznih značajki.

Povećavanjem broja konvolucijskih slojeva u mreži, svaki slijedeći sloj može modelirati interakciju veće regije ulaznih značajki. Drugim riječima, svaka značajka ima svoje receptivno polje, koje definira domet ili raspon ulaznih značajki čiji iznosi utječu na njen izračun. Zato receptivno polje aktivacija konvolucijskog modela raste s dubinom.

Jedna varijanta diskretne konvolucijske operacije je dubinska konvolucija (engl. *depthwise convolution*). Razlikuje se od prve varijante u tome što jezgra ne prolazi istovremeno kroz sve dimenzije kanala, već svaki kanal ima svoju posebnu jezgru. U slučaju slike, koja ima kanale ekvivalentne bojama, ova jezgra se zapravo sastoji od više jezgara koje odgovaraju broju kanala na ulazu. Svaka jezgra će odraditi klasičnu konvoluciju na svojem kanalu te proizvesti mapu značajki za taj kanal. Ako imamo 3 kanala, ekvivalentno bojama slike ili 64 kanala ekvivalentno elektrodama na signalu EEG-a, jedna operacija će proizvesti 3 odnosno 64 mape koje se na kraju slažu jedna na drugu.

Sljedeća varijanta spomenute dubinske konvolucije jest separabilna dubinska konvolucija. Ona se razlikuje od prethodne u tome što nakon slaganja svih mapi značajki kanala u jednu mapu, nad tom mapom se obavlja još jedna operacija konvolucije nad dimenzijom kanala. Na kraju ove operacije mapa značajki će biti spljoštena po dimenziji kanala u odnosu na dubinsku konvoluciju.



Slika 3.7 Dubinska i Separabilna konvolucija [16]

U CNN-u uz konvolucijske slojeve nailazimo i na slojeve sažimanja (engl. *pooling layer*). Sloj sažimanja dodatno smanjuje veličinu mape značajki koristeći neku funkciju kojom „rezimira“ subregije kao što su maksimalna vrijednost ili srednja vrijednost. Sloj sažimanja se računa poput konvolucije klizeći po regijama ulazne mape.



Slika 3.8 Arhitektura CNN za klasifikaciju slika [14]

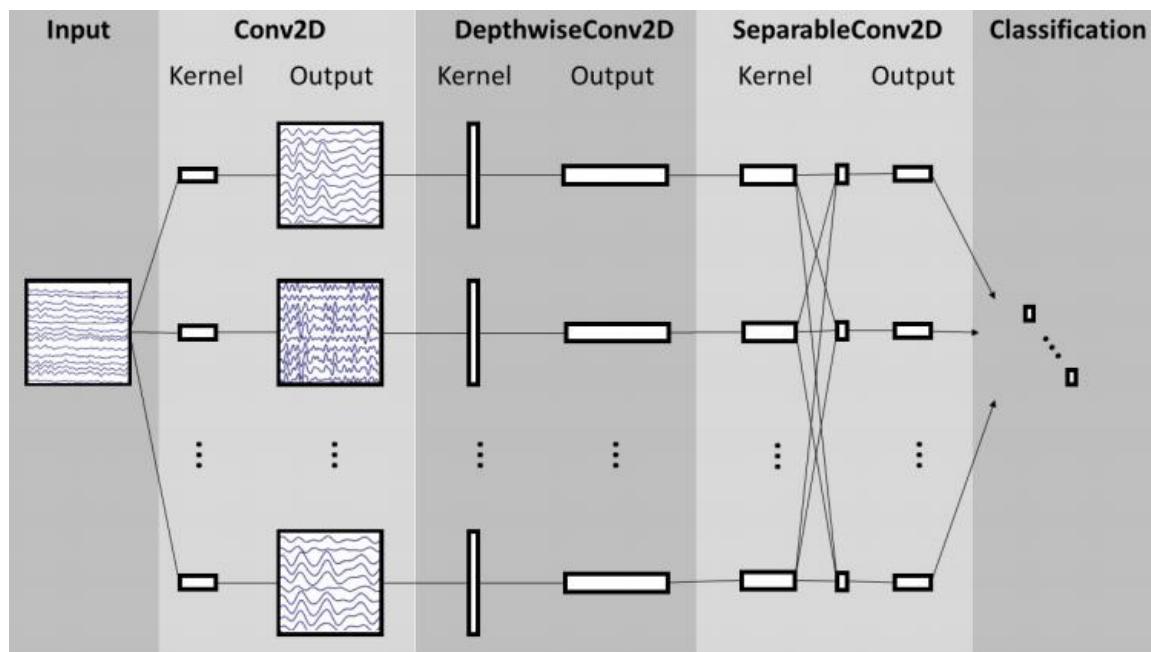
3.2.3. Korištena arhitektura

Za klasifikacije oba skupa podataka korištena je arhitektura modela predstavljenog kao EEGNet u radu [18]. Model je implementiran u programskom jeziku python koristeći biblioteke keras i tensorflow.

Odabir ove arhitekture je proizašao zbog želje da model samostalno konstruira značajke iz sirovih signala. Konvolucijske neuronske mreže daju jako dobre rezultate u klasifikaciji slika u zadacima računalnog vida, ali isto tako i njihova popularnost u zadnjih par godina raste i za klasifikaciju signala EEG-a [20][21][22].

Ovaj model se sastoji od običnog sloja konvolucije, dubinske konvolucije te separabilne konvolucije. Regularizacija se ostvaruje preko slojeva grupne normalizacije te ispuštanja. Na kraju mreže se naravno nalazi potpuno povezani sloj. Hiperparametri ove mreže su bili;

- F1 – broj temporalnih filtera
- F2 – broj filtera u separabilnom konvolucijskom sloju
- D – broj spacialnih filtera u svakoj temporalnoj konvoluciji



Slika 3.9 Slojevi u EEGNet modelu [18]

3.2.4. Optimizacija

Za učenje modela koristio se algoritam Adam koji ime dobiva od Adaptive Moments. Prema autorima u izvornom radu [17], opisuje se kao stohastički gradijentni spust (SGD) baziran na adaptivnim procjenama momenata prvog i drugog reda.

Adam računa pristranu procjenu momenta gradijenata i kvadrata gradijenata uz eksponencijalno zaboravljanje. Zatim računa korigiranu procjenu momenta na temelju prvotnih procjena. Ta korekcija se radi prema uprosječenom gradijentu a ne izračunatom (efekt momenta).

Autori ovaj algoritam opisuju kao računalno efikasan, s malim zahtjevima na memoriju, invarijantan na dijagonalno skaliranje gradijenata te prigodan za probleme s velikim brojem parametara i podataka [17].

Require: α : Stepsize
Require: $\beta_1, \beta_2 \in [0, 1]$: Exponential decay rates for the moment estimates
Require: $f(\theta)$: Stochastic objective function with parameters θ
Require: θ_0 : Initial parameter vector

$m_0 \leftarrow 0$ (Initialize 1st moment vector)
 $v_0 \leftarrow 0$ (Initialize 2nd moment vector)
 $t \leftarrow 0$ (Initialize timestep)

while θ_t not converged **do**

- $t \leftarrow t + 1$
- $g_t \leftarrow \nabla_{\theta} f_t(\theta_{t-1})$ (Get gradients w.r.t. stochastic objective at timestep t)
- $m_t \leftarrow \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t$ (Update biased first moment estimate)
- $v_t \leftarrow \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2$ (Update biased second raw moment estimate)
- $\hat{m}_t \leftarrow m_t / (1 - \beta_1^t)$ (Compute bias-corrected first moment estimate)
- $\hat{v}_t \leftarrow v_t / (1 - \beta_2^t)$ (Compute bias-corrected second raw moment estimate)
- $\theta_t \leftarrow \theta_{t-1} - \alpha \cdot \hat{m}_t / (\sqrt{\hat{v}_t} + \epsilon)$ (Update parameters)

end while
return θ_t (Resulting parameters)

Slika 3.10 Pseudokod algoritma Adam [17]

3.2.5. Vrednovanje klasifikatora

Točnost (eng. *accuracy*) je jedna mjera za evaluaciju klasifikacijskog modela. To je omjer točnih i svih predikcija. Za binarnu klasifikaciju, moguće je definirati točnost kroz omjer pozitivnih i negativnih primjeraka klasifikacije.

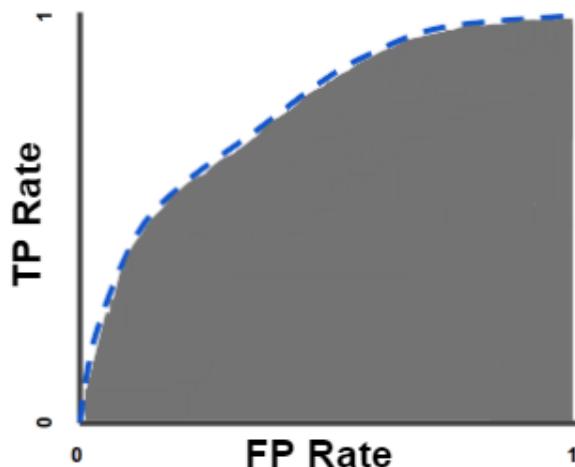
$$Točnost = \frac{Broj točnih predikcija}{Broj ukupnih predikcija} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Točnost je jednostavna mjera klasifikatora koja daje sliku o mogućnostima modela. Međutim, ona može davati krivu sliku o sposobnostima klasifikatora jer ovisi o balansu klasa koje se nalaze u skupovima za analizu, stoga je prikladna mjera za balansirane skupove podataka.

AUC (engl. *area under curve*) ili površina ispod krivulje je metrika koja mjeri upravo to. Krivulja koja se najčešće koristi je ROC (engl. *receiver operating characteristic curve*). Ta krivulja prikazuje sposobnosti modela na svim mogućim pragovima podjele klase. Krivulja ima dva parametra a to su *true positive rate* (TPR) i *false positive rate* (FPR).

$$TPR = \frac{TP}{TP+FP} \quad FPR = \frac{FP}{FP+TN} \quad (2)$$

Intuitivno objašnjenje što AUC-ROC mjera predstavlja je vjerojatnost da će slučajno odabrani pozitivni primjer biti rangiran desno od slučajno negativnog primjera.



Slika 3.11 ROC krivulja i AUC ispod nje [19]

Prednost AUC mjere nad točnosti je u tome što bolje evaluira modele koji rade s loše balansiranim skupovima podataka tako da kažnjava modele koji ne diskriminiraju dobro između klasa. Jedan od nedostatka AUC-a je u tome što nije dobra mjera ukoliko želimo minimizirati FP na račun FN što ponekad i želimo.

4. Rezultati analize

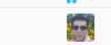
4.1. Analiza skupa podataka ERN

U obradi ovog skupa podataka, klasifikacija modela je testirana temeljem podjele na dva načina.

Prva podjela je zapravo ista ona koja je bila zadatak Kaggleovog natjecanja 2015. godine. Klasifikator je učen na 16 subjekata, a testiran na 10. To znači da su to dva odvojena skupa subjekata te je poanta bila prijenos učenja na druge subjekte (engl. *cross-subject learning* ili ponekad *transfer learning*). Prijenos učenja je metoda u strojnom učenju kojom se modeli tj. znanja naučena na jednom skupu podataka, primjenjuju na jedan drugačiji ali sličan problem odnosno skup podataka. U ovom kontekstu se prenosi znanje naučeno s jednog skupa subjekata na druge.

Točne oznake povratnih sjednica nisu poznate za ispitni skup, već je moguće samo preko Kaggleove službene stranice natjecanja dobiti ocjenu klasifikatora. Nakon što se nauči klasifikator, potrebno je rezultate nad ispitnim skupom spremiti u .csv datoteku te rezultate objaviti na spomenutoj stranici koja će automatski izračunati AUCROC ocjenu.

■ In the money ■ Gold ■ Silver ■ Bronze

| # | Δpub | Team Name | Notebook | Team Members | Score 📈 | Entries | Last |
|----|-------|--------------------------|----------|---|---------|---------|------|
| 1 | — | the overfitting avengers | |  | 0.87224 | 32 | 5y |
| 2 | — | Devin | |  | 0.85668 | 44 | 5y |
| 3 | ▲ 17 | H2O.ai | |  | 0.81849 | 30 | 5y |
| 4 | ▲ 2 | barrack_d(NER) | |  | 0.76921 | 110 | 5y |
| 5 | ▲ 53 | Jose M. | |  | 0.74789 | 3 | 6y |
| 6 | ▲ 8 | CSL (NER) | |  | 0.74569 | 27 | 5y |
| 7 | ▲ 46 | Daniel Yoo | |  | 0.73174 | 6 | 5y |
| 8 | ▼ 1 | Vivien | |  | 0.72325 | 38 | 5y |
| 9 | ▲ 3 | khyh | |  | 0.72303 | 56 | 5y |
| 10 | ▼ 1 | clustifier | |  | 0.71650 | 70 | 5y |
| 11 | ▲ 63 | brainsignals | |  | 0.71473 | 11 | 5y |
| 12 | ▲ 33 | ThibaultV | |  | 0.70151 | 20 | 5y |
| 13 | ▲ 136 | A.M. | |  | 0.69864 | 11 | 5y |
| 14 | ▲ 29 | os | |  | 0.69467 | 12 | 5y |
| 15 | ▲ 12 | Black Swan (NER) | |  | 0.69364 | 39 | 5y |

Slika 4.1 Rang ljestvica rezultata Kaggle natjecanja

Rezultate ove analize je moguće usporediti s rangiranim rezultatima natjecanja pojedinih timova. Postoje dva ranga, jedan privatni koji je izračunat s 20% podataka te javni koji je izračunat s 80% podataka iz skupa za testiranje. Kako je to bilo javno natjecanje, skup za testiranje je podijeljen na dva dijela kako bi se onemogućilo timovima namještavanje rezultata. Rezultate klasifikatora su stoga uspoređeni samo s javnom rang ljestvicom, za koju je moguće vidjeti prvih 15 timova te odgovarajuće AUCROC ocjene.

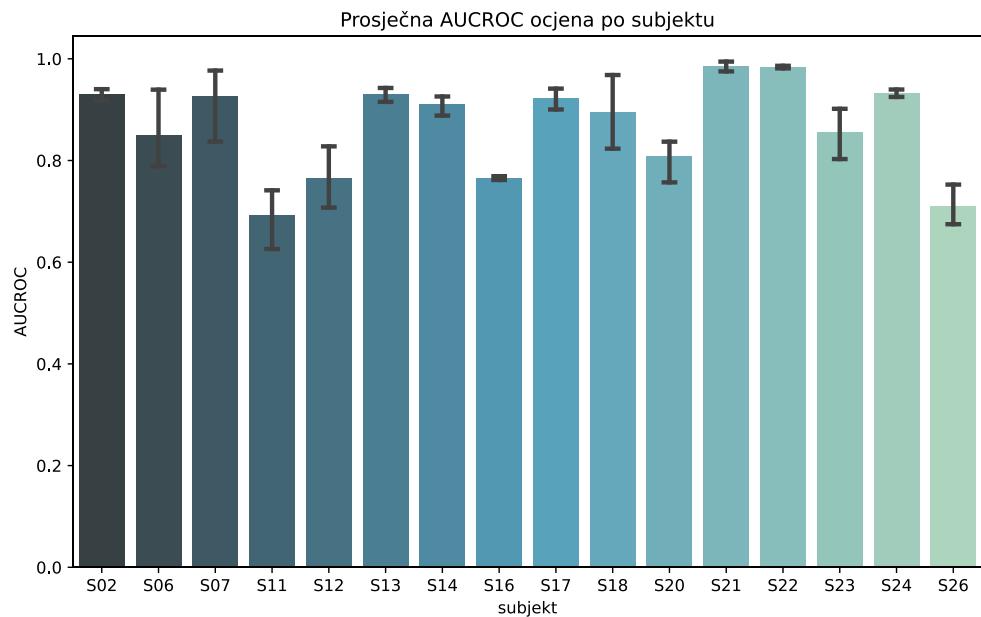
Hiperparametri modela su dobiveni na temelju validacijskog skupa koji je dobiven 4-strukom unakrsnom validacijom, a to su $D=4$, $F1 = 7$, $F2 = 8$. Rezultat koji je postignut je AUCROC ocjena od 0.80682. Uspoređujući s rezultatima natjecatelja koji su svoje rezultate ostvarili 2015. godine, ovaj rezultat bi se našao na četvrtom mjestu, za dlaku ispod trećeg mesta koje je osvojilo nagradu. Prvo mjesto ipak ima dosta bolji rezultat.

Drugom analizom na ovom skupu podataka je testirano kako ova arhitektura modela radi kada se učenje i ispitivanje obavlja nad podacima od istog ispitanika. Na temelju prethodnih rezultata dokazali smo da je moguće ostvariti relativno zadovoljavajuće razine klasifikacije nad ispitanicima čije valove nismo koristili za učenje. Međutim, svaki mozak je poseban i proizvodi specifične moždane valove koji se odražavaju u morfologiji signala EEG-a. Te male varijacije utječu na razinu sposobnosti klasifikacije. U idealnom slučaju, za svakog ispitanika bi se prikupio poveći skup podataka te bi učenje posebnog klasifikatora za svakog ispitanika proizvelo bolje rezultate. Međutim, prikupljanje tih podataka je jako skup i vremenski zahtjevan posao te zbog toga postoji težnja za izgradnjom sustava koji nije potrebno kalibrirati za svaku osobu posebno.

Zbog malog skupa podataka po subjektu, procjena sposobnosti modela je obavljena 4-strukom unakrsnom evaluacijom, istom tehnikom kao što su i autori EEGNet modela evaluirali ovu analizu. Hiperparametri su birani na temelju gubitka validacijskog skupa, koji je bio sagrađen od 20% primjera za učenje u svakom preklopu, koristeći se sklearn metodom train_test_split sa stratifikacijom. Na temelju rezultata iz validacijskog skupa, izabrani su hiperparametri i broj epoha za učenje kako bi se na kraju model učio i na primjerima za validaciju.

Na donjoj slici 4.2, vidljivi su rezultati ove analize. Uzrok varijacija rezultata između ispitanika može biti zbog prirodne razlike u morfologiji valova koje svaki ispitanik proizvodi. Međutim, veće razlike su vjerojatno rezultat slabe koncentracije pojedinih ispitanika. Iz grafa je vidljivo da individualno učenje klasifikatora za svakog ispitanika daje nedvojbeno bolje rezultate kada se usporedi s prethodnom analizom. Srednja vrijednost

AUCROC ocjene svih ispitanika jest 0.86675. To znači da ova arhitektura nije prikladna za izgradnju klasifikatora koji dobro generalizira nad ispitanicima čiji podaci nisu viđeni, ali zato daje jako dobre rezultate kada se obavi individualna kalibracija klasifikatora. U ovom slučaju, dobri rezultati su ostvareni s ograničenim brojem primjera za učenje.



Slika 4.2 Klasifikatori izgrađeni posebno za svakog ispitanika

4.2. Analiza glazbenog skupa podataka

Nad ovim skupom podataka je provedena klasifikacija na dva načina te je svaki način bio podložan inter i intra subjektnoj analizi. Prilikom optimizacije modela, fokus je bio na hiperparametrima D, F1 i F2, te se za svaki podzadatak pretraživao isti skup hiperparametara.

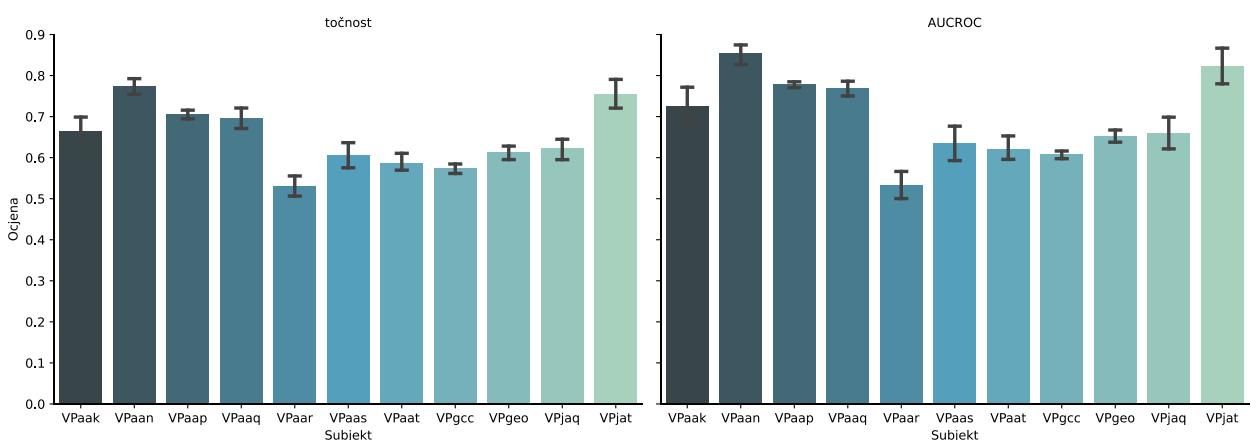
4.2.1. Binarna klasifikacija

U prvoj analizi, gledala se klasifikacija između fokusiranih i nefokusiranih devijanata, te je prvi klasifikator izgrađen za inter-subjektnu analizu. Procjena klasifikatora je ostvarena 4-strukom unakrsnom evaluacijom, dok su hiperparametri bili birani na temelju validacijskog skupa koji je bio sastavljen od dva slučajno odabrana subjekta iz skupa za učenje u svakom od 4 preklopa. Na temelju rezultata nad validacijskim skupom, hiperparametri D=4, F1=8 te F2= 16 su odabrani kao optimalni za svaki preklop, dok je broj epoha bio različit za svaki

preklop. Nakon toga, model je bio učen i nad podacima iz validacijskog skupa, pošto pregledom grafa učenja nije dolazilo do signifikantne prenaučenosti. Nad ovakvom podjelom podataka ostvarena je točnost od 0.63 te AUCROC ocjena od 0.68.

Slični rezultati su ostvareni prilikom izgradnje posebnog klasifikatora za svakog ispitanika. Odabrani hiperparametri su bili $D = 2$, $F1 = 8$, $F2 = 8$ te broj epoha je odabran posebno za svaki preklop. Za ocjenu klasifikatora je korištena 4-ostruka unakrsna evaluacija, a odabir hiperparametara je odrđen na isti način kao i kod prethodne analize. Srednja vrijednost točnosti između svih klasifikatora iznosi 0.65, dok je AUCROC ocjena 0.70.

Ovi rezultati ne podržavaju previše očekivanje da će individualni klasifikatori proizvesti bolje rezultate, što je vrlo očigledno u analizi prethodnog skupa podataka, ali i u srodnim istraživanjima. Iz grafova na slici 4.3, je vidljivo koliko varira klasifikacija po ispitaniku. Ispitanik s kodom „VPaar“ je postigao jako loše rezultate te ukoliko za njega nije moguće individualno izgraditi sposoban klasifikator, njegovi podaci zapravo imaju loš učinak i na grupne klasifikatore. S druge strane, za ispitanike poput VPaan i VPjat je bilo moguće izgraditi iznimno sposobne klasifikatore. Ovakvi slučajevi ukazuju na važnost dobrih podataka, a pitanje zašto postoje tolike razlike su naravno višestruke. Koncentracija ispitanika je zasigurno jedan veliki faktor. Ukoliko ispitanik ne obraća pozornost na eksperiment to će se zasigurno odraziti i na EEG snimci njegove moždane aktivnosti. Druga mogućnost je jednostavno čista stvar fizionomije ispitanika. Možda ispitanik ima suhu kožu što rezultira slabim prodorom električnih valova do elektroda na površini glave.



Slika 4.3 Rezultati individualnih binarnih klasifikatora

Uz ove dvije navedene izgradnje klasifikatora s obzirom na učenje prijenosom ili izgradnju klasifikatora individualno za svakog ispitanika je bila izgradnja generalnog klasifikatora koristeći sve ispitanike u skupu za učenje i testiranje. Podaci su podijeljeni na skup za

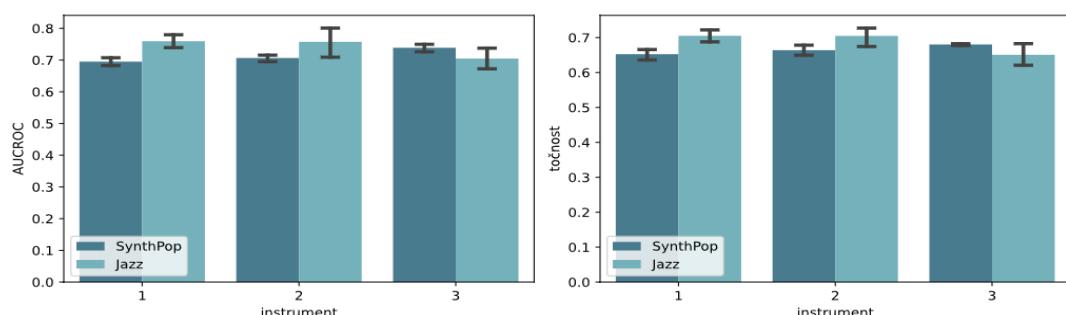
testiranje od 20% svih podataka tako da oba skupa imaju jednaki omjer fokusiranih devijanata te ispitanika. Za ovu analizu nije korištena unakrsna evaluacija već je skup za testiranje odabran koristeći metodu `train_test_split` s `random_state` parametrom namještenim na 28.

Za odabir hiperparametara korišten je validacijski skup koji je bio odabran na identičan način kao i ispitni skup, ali iz skupa za učenje. Na kraju su odabrani hiperparametri $D=4$, $F1=8$, $F2 = 16$ i 300 epoha, a ostvarena je točnost od 0.70 i AUCROC od 0.77. Ovi rezultati su daleko najviši od svih provedenih u prvoj vrsti analize, što je vidljivo u tablici 4.1.

4.2.2. Klasifikacija po instrumentima

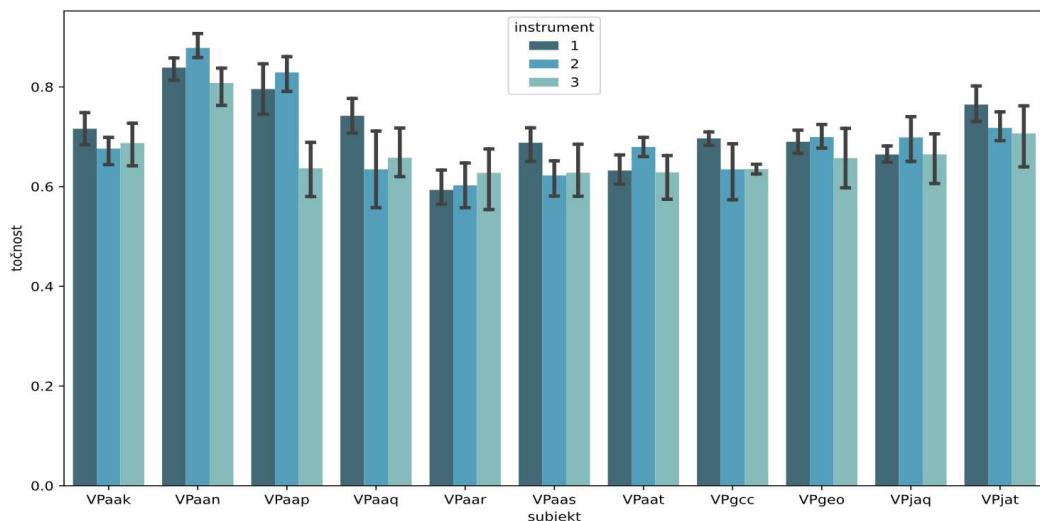
U drugom dijelu analize ovog skupa podataka je ispitivano da li je morfologija odaziva ovisna o instrumentu. Stoga su podaci podijeljeni prvo prema vrsti glazbenog odsječka, a zatim dodatno u tri grupe, jednu za svaki instrument. Za svaki instrument je izgrađen poseban klasifikator kojemu je cilj raspozнатi između odaziva na fokusirani devijant i nefokusirani devijant istog instrumenta. Podaci su ponovno bili podijeljeni na tri načina te su ispitana tri aspekta učenja prijenosom, individualno i generalno.

Za početak je analizirana sposobnost prijenosa učenja na druge ispitanike. Ocjena sposobnosti modela je obavljena 4-strukom unakrsnom evaluacijom, dok je validacijski skup sadržavao 20% subjekata iz skupa za učenje iz svakog preklopa. Pregledom grafa kretanja gubitka, skup hiperparametara $D=2$, $F1=2$, $F2=4$ je odabran zbog najmanje varijacije i konzistentnosti rezultata. Srednja vrijednost točnosti kroz sve instrumente i žanrove je 0.68, dok je AUCROC 0.73. Očito da su to različiti podraznaji te da će ih svaka osoba prepoznati kao drugačije, međutim bilo je pitanje da li to sustav BCI može razaznati. U ovom slučaju su dobiveni bolji rezultati nego prilikom binarne klasifikacije. Na grafu ispod su vidljivi rezultati prijenosa učenja među ispitanicima po instrumentu i žanru.

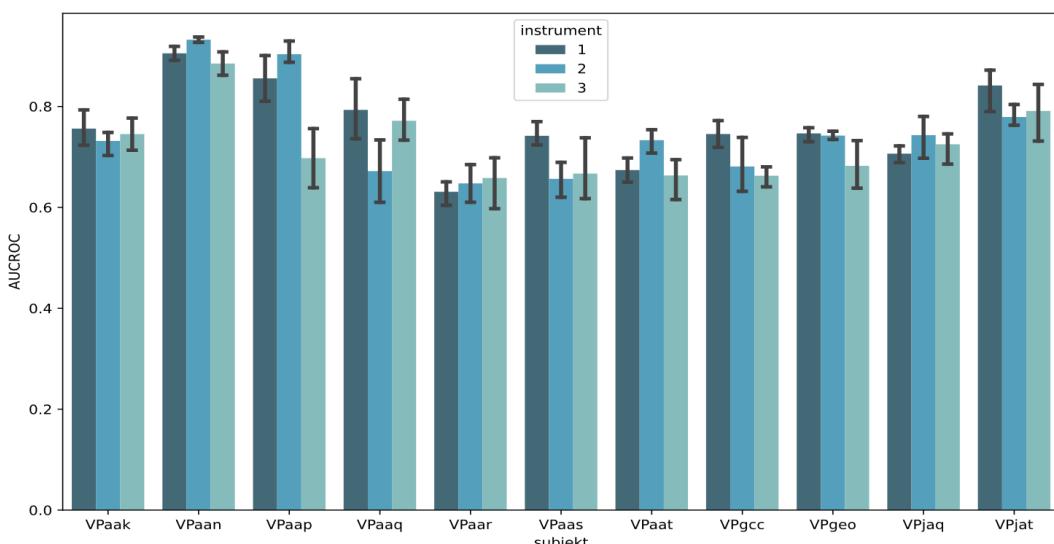


Slika 4.4 Učenje prijenosom po instrumentu

Glazba pobuđuje različite osjećaje među osobama, isti zvuk može jednoj osobi biti ugodan, dok drugoj neugodan, stoga će slijedeća analiza gdje su klasifikatori izgrađeni po ispitaniku dati bolji uvid o sposobnostima modela za raspoznavanje instrumenata i kakvog efekta imaju na pojedine ispitanike. U ovoj analizi, ocjena klasifikatora je obavljena 4-strukom unakrsnom evaluacijom, dok je skup za validaciju bio sagrađen od 20% primjera za učenje iz svakog preklopa. Hiperparametri su birani za svaki preklop na temelju rezultata iz validacijskog skupa. Hiperparametri su automatski izabrani na temelju najmanjeg gubitka validacije, te je također zapamćen i broj epoha kako bi se mogao učiti model i nad validacijskim skupom. Srednja vrijednost točnosti izračunata kroz sve subjekte, instrumente te žanrove iznosi 0.69, dok AUCROC iznosi 0.74.



Slika 4.5 Točnost individualnih klasifikatora po instrumentu



Slika 4.6 AUCROC individualnih klasifikatora po instrumentu

I zadnja analiza provedena na ovom skupu podataka je generalno učenje posebnih klasifikatora. Što znači da se modeli uče i testiraju na podacima sakupljenim od svih subjekata ali odvojeno po instrumentima i žanrovima. U ovoj analizi, skup za ispitivanje se sastojao od 20% podataka svih podataka, dok je validacijski skup bio sačinjen od 20% podataka iz skupa za učenje. Rezultat ove analize je prosječna točnost od 0.69 te AUCROC od 0.74.

Tablica 4.1 Rezultati klasifikatora za različite podjele podataka

| | Binarni | | Po instrumentima | |
|--------------|---------|--------|------------------|--------|
| | Točnost | AUCROC | Točnost | AUCROC |
| Prijenos | 0.63 | 0.68 | 0.68 | 0.73 |
| Individualni | 0.65 | 0.70 | 0.69 | 0.74 |
| Generalni | 0.70 | 0.77 | 0.69 | 0.74 |

Iz tablice se vidi da su rezultati po instrumentima konzistentni i ne ovise o vrsti analize, što je čudno pošto bi zasigurno individualni rezultati morali biti bar do neke mjere bolji od onih dobivenih prijenosom. Razlog tome bi moglo biti drastično smanjenje primjera za učenje što za ovaj skup podataka u konačnici ima kontra efekt prilikom izgradnje individualnih klasifikatora.

4.2.3. Odabir instrumenta u glazbenom odsječku

U prethodne dvije analize ispitivane su mogućnosti modela u single trial klasifikaciji. Za vrijeme pisanja rada, nisu pronađeni nijedni radovi koji su na ovaj način obradili ovaj skup podataka, te je jedino poznata analiza izvornih autora. Autori su u tom radu ocjenu klasifikatora računali tako što su skup podataka podijelili na glazbene odsječke te je cilj bio odrediti na koji instrument je ispitanik bio fokusiran. U jednom glazbenom odsječku se nalazi između 3 do 15 devijacija tj. single trial-a, te je cilj na temelju svih tih devijacija odrediti na koji instrument se ispitanik fokusira. Stoga u svrhu usporedbe mogućnosti ove arhitekture s rezultatima drugih radova, izgrađena su još dva sustava.

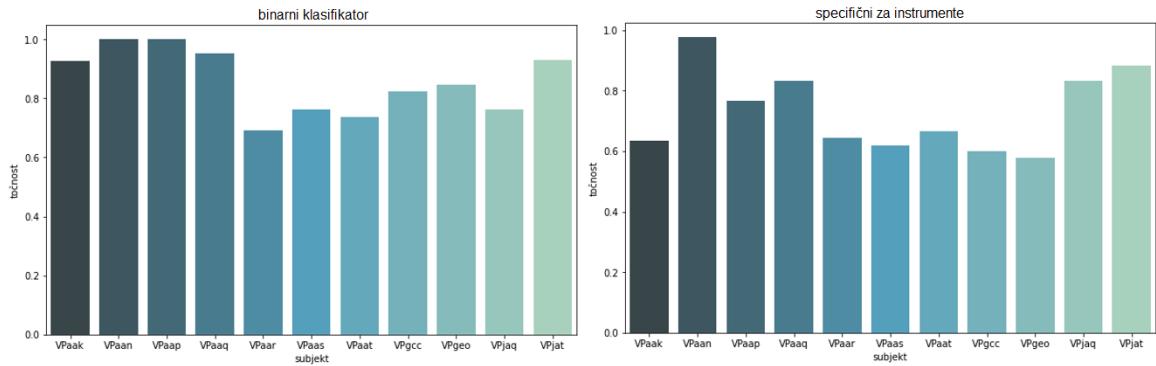
Za oba klasifikatora korištena je 5-struka unakrsna evaluacija za ocjenu modela. Traženje hiperparametara je odrđeno nad validacijskom skupu podataka, koji se sastojao od 20% glazbenih odsječaka iz skupa za učenje. Koristila se fiksna podjela dobivena iz sklearn metode GroupShuffleSplit s parametrom random_state = 23. Parametri koji su se

optimizirali su F1, F2, D te broj epoha. Nakon pronađaska najboljeg skupa hiperparametara, model je bio učen i na validacijskom skupu.

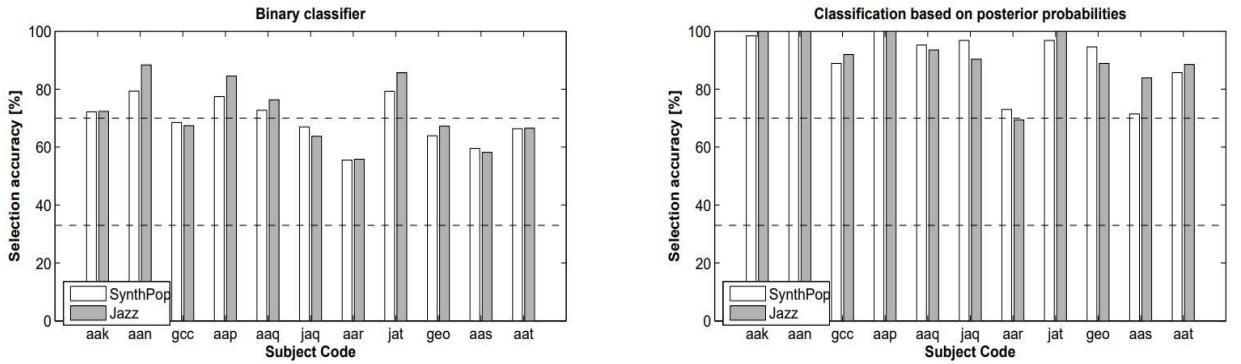
Pri izgradnji binarnog modela, odabrani su hiperparametri D=4, F1=16, F2=32 te fiksani broj epoha 225.

Za slučaj klasifikacije bazirane nad pojedinim klasifikatorima instrumenata, izabrani su sljedeći hiperparametri, D=2, F1=8, F2=16 te broj epoha je dinamički izabran za svaku podjelu posebno, s maksimalnim brojem epoha od 350.

Rezultati po subjektu su vidljivi u donja dva grafa 4.7 i 4.8., ovog rada i izvornih autora.



Slika 4.7 Rezultati selekcije instrumenata iz glazbenih odsječaka. Lijevo se nalazi binarni, dok se desno nalazi klasifikator baziran na instrumentima



Slika 4.8 Rezultati analize izvornih autora [10]

Srednja vrijednost točnosti izvornog rada za binarni klasifikator iznosi 70.36%, dok za klasifikator baziran na instrumentima iznosi 91.25%. Rezultati ovog rada su 86.72% za binarni klasifikator, dok je klasifikator baziran na instrumentima ostvario točnost od 70.75%.

Razlike u analizi su svakako zanimljive pošto daju potpuno drugačije rezultate, u ovom radu su znatno bolji rezultati kod binarnog klasifikatora, dok je selekcija bazirana na instrumentima dala signifikantno bolje rezultate kod izvornih autora.

Pitanje je zašto model koji je korišten u ovom radu, baziran na instrumentima dao znatno lošije rezultate od modela izvornih autora, no daje bolje kod binarnog modela. Ovakav rezultat također nije posve jasan kada su rezultati u single trial analizi po subjektima bili bolji prilikom izgradnje klasifikatora po instrumentima nego binarnih. Razlika između rezultata u selekciji instrumenata i single trial klasifikaciji su vjerojatno rezultat podjele skupa za učenje i ispitivanje po glazbenim odsjećcima u selekciji dok u single trial analizi nisu. Drugi razlog je također samo činjenica da točnost nije često prelazila prag od 70% u single trial klasifikaciji, što je zapravo dosta nisko, stoga sustav baziran na tome neće biti pouzdan.

Drugo pitanje koja se tu postavlja, koliko je zapravo ova paradigma praktična za korištenje u sustavima BCI. Selekcija instrumenta, u ovom eksperimentalnom dizajnu daje mogućnost odabira samo 3 naredbe. Sa samo tri naredbe, sustav BCI je znatno limitiran, međutim kao prednosti se navodi ugodno iskustvo korištenja kroz slušanje glazbe, što je zasigurno istina. Ako se pogleda koliko traje jedan glazbeni odsječak, a to je 40 sekundi, to efektivno daje prespor sustav za većinu namjena.

Zaključak

U ovom radu je predmet analize bilo sučelje između čovjeka i računala. Zbog toga je provedeno kratko upoznavanje s neuroznanošću kroz fiziologiju mozga i morfologiju elektroencefalograma. Navedene su komponente koje su bile predmet praktične analize u ovom radu.

Ispitivale su se dvije komponente, auditorni P300 te vizualni ERN kroz dva različita skupa podataka. Svaki skup podataka je proveden kroz korake predobrade, a zatim podijeljen s obzirom na tip učenja, u kojem se moglo ispitivati mogućnost učenja s prijenosom na subjekte, individualnog učenja po subjektima te generalnog pomiješanog učenja.

Za klasifikaciju signala korišten je konvolucijski model neuronske mreže arhitekture EEGNet.

Na glazbenom skupu podataka P300 model nije dao uvjerljive rezultate kada govorimo o sposobnosti detekcije svakog događaja, te pri izgradnji klasifikatora po instrumentima nije dokazana razlika između učenja s transferom na subjekte te individualnog učenja. Ali zato u analizi skupa podataka ERN, model je ostvario AUCROC ocjenu 0.81 za prijenos učenja među subjektima, te prosječni AUCROC od 0.87 po subjektima.

Literatura

- [1] Judaš M, Kostović I (2001) Temelji neuroznanosti, 1. online izdanje. MF Zagreb – HIIM web stranica (<http://www.hiim.hr>)
- [2] Kaan, E. (2007). Event-Related Potentials and Language Processing: A Brief Overview. *Lang. Linguistics Compass*, 1, 571-591.
- [3] “10–20 System (EEG).” Wikipedia, 21 Oct. 2019, [https://en.wikipedia.org/wiki/10%E2%80%9320_system_\(EEG\)](https://en.wikipedia.org/wiki/10%E2%80%9320_system_(EEG)).
- [4] Vidal, J J. “Toward Direct Brain-Computer Communication.” *Annual Review of Biophysics and Bioengineering* 2, no. 1 (June 1, 1973): 157–80. <https://doi.org/10.1146/annurev.bb.02.060173.001105>.
- [5] Wolpaw JR, Winter Wolpaw E. Brain-computer interfaces: something new under the sun. In: Wolpaw JR, Winter Wolpaw E. *Brain-computer interfaces: principles and practice*, pp. 3-12, Oxford University Press, New York, 2012.
- [6] Zander TO, Kothe C. Towards passive brain-computer interfaces: applying brain-computer interface technology to human-machine systems in general. *J Neural Eng*, 8:025005, 2011.
- [7] Mak JN, Wolpaw JR. Clinical applications of brain-computer interfaces: current state and future prospects. *IEEE Rev Biomed Eng*. 2009;2:187-199
- [8] Perrin, M., Maby, E., Daligault, S., Bertrand, O., & Mattout, J. Objective and subjective evaluation of online error correction during P300-based spelling. *Advances in Human-Computer Interaction*, 2012, 4.
- [9] “BCI Challenge @ NER 2015.” Pristupio 18.6.2020. <https://kaggle.com/c/inria-bci-challenge>.
- [10] Treder, M S, H Purwins, D Miklody, I Sturm, and B Blankertz. “Decoding Auditory Attention to Instruments in Polyphonic Music Using Single-Trial EEG Classification.” *Journal of Neural Engineering* 11, no. 2 (April 1, 2014): 026009. <https://doi.org/10.1088/1741-2560/11/2/026009>.
- [11] SHARMA, S. “What the Hell Is Perceptron?” Medium, October 11, 2019. <https://towardsdatascience.com/what-the-hell-is-perceptron-626217814f53>.
- [12] Hjorth-Jensen, M. “Convolutional Neural Networks.” Pristupio 18.6.2020. https://compphysics.github.io/MachineLearning/doc/pub/cnn/html/._cnn-bs000.html.
- [13] LeCun, Y., Haffner, P., Bottou, L., Bengio, Y., 1999. Object Recognition with Gradient-Based Learning, in: Forsyth, D.A., Mundy, J.L., di Gesù, V., Cipolla, R. (Eds.), *Shape, Contour and Grouping in Computer Vision, Lecture Notes in Computer Science*. Springer, Berlin, Heidelberg, pp. 319–345. https://doi.org/10.1007/3-540-46805-6_19
- [14] Šegvić, Š., Krapac, J., „Konvolucijski modeli“, <http://www.zemris.fer.hr/~ssegvic/du/du2convnet.pdf>
- [15] Dumoulin, V., Visin, F., 2018. A guide to convolution arithmetic for deep learning. arXiv:1603.07285 [cs, stat].

- [16] Pandey, A., 2018. Depth-wise Convolution and Depth-wise Separable Convolution [WWW Document]. Medium. URL <https://medium.com/@zurister/depth-wise-convolution-and-depth-wise-separable-convolution-37346565d4ec> (Pristupio 19.6.20).
- [17] Kingma, D.P., Ba, J., 2017. Adam: A Method for Stochastic Optimization. arXiv:1412.6980 [cs].
- [18] Lawhern, V.J., Solon, A.J., Waytowich, N.R., Gordon, S.M., Hung, C.P., Lance, B.J., 2018. EEGNet: A Compact Convolutional Network for EEG-based Brain-Computer Interfaces. *J. Neural Eng.* 15, 056013. <https://doi.org/10.1088/1741-2552/aace8c>
- [19] Classification: ROC Curve and AUC | Machine Learning Crash Course [WWW Document], n.d. . Google Developers. URL <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc> (Pristupio 19.6.20).
- [20] Gu, X., Cao, Z., Jolfaei, A., Xu, P., Wu, D., Jung, T.-P., Lin, C.-T., 2020. EEG-based Brain-Computer Interfaces (BCIs): A Survey of Recent Studies on Signal Sensing Technologies and Computational Intelligence Approaches and their Applications. arXiv:2001.11337 [cs, eess].
- [21] Convolutional Neural Network for a P300 Brain-Computer Interface to Improve Social Attention in Autistic Spectrum Disorder | Request PDF [WWW Document], n.d. . ResearchGate. http://dx.doi.org/10.1007/978-3-030-31635-8_223
- [22] Roy, Y., Banville, H., Albuquerque, I., Gramfort, A., Falk, T.H., Faubert, J., 2019. Deep learning-based electroencephalography analysis: a systematic review. *J. Neural Eng.* 16, 051001. <https://doi.org/10.1088/1741-2552/ab260c>
- [23] Neural coding, 2020. . Wikipedia.
- [24] Wang, Y., Wu, D., 2018. Real-time fMRI-based Brain Computer Interface: A Review. arXiv:1808.05852 [cs].
- [25] Al-Fahoum, A., Al-Fraihat, A., 2014. Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains. *ISRN neuroscience* 2014, 730218. <https://doi.org/10.1155/2014/730218>
- [26] Shin, J., Müller, K.-R., Hwang, H.-J., 2016. Near-infrared spectroscopy (NIRS)-based eyes-closed brain-computer interface (BCI) using prefrontal cortex activation due to mental arithmetic. *Scientific Reports* 6, 36203. <https://doi.org/10.1038/srep36203>
- [27] Bu, J., Young, K.D., Hong, W., Ma, R., Song, H., Wang, Y., Zhang, W., Hampson, M., Helder, T., Zhang, X., 2019. Effect of deactivation of activity patterns related to smoking cue reactivity on nicotine addiction. *Brain* 142, 1827–1841. <https://doi.org/10.1093/brain/awz114>
- [28] Stavisky, S.D., Rezaii, P., Willett, F.R., Hochberg, L.R., Shenoy, K.V., Henderson, J.M., 2018. Decoding Speech from Intracortical Multielectrode Arrays in Dorsal “Arm/Hand Areas” of Human Motor Cortex, in: 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Presented at the 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), IEEE, Honolulu, HI, pp. 93–97. <https://doi.org/10.1109/EMBC.2018.8512199>

- [29] Millan, J. del R., 2008. Error-Related EEG Potentials Generated During Simulated Brain–Computer Interaction. *IEEE transactions on bio-medical engineering* 55, 923–9. <https://doi.org/10.1109/TBME.2007.908083>
- [30] Kumar, A., Gao, L., Pirogova, E., Fang, Q., 2019. A Review of Error-Related Potential-Based Brain–Computer Interfaces for Motor Impaired People. *IEEE Access* 7, 142451–142466. <https://doi.org/10.1109/ACCESS.2019.2944067>
- [31] Spüler, M., Bensch, M., Kleih, S., Rosenstiel, W., Bogdan, M., Kübler, A., 2012. Online use of error-related potentials in healthy users and people with severe motor impairment increases performance of a P300-BCI. *Clin Neurophysiol* 123, 1328–1337. <https://doi.org/10.1016/j.clinph.2011.11.082>
- [32] Putze, F., Amma, C., Schultz, T., 2015. Design and Evaluation of a Self-Correcting Gesture Interface Based on Error Potentials from EEG. Presented at the Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems, ACM, pp. 3375–3384.
- [33] Ehrlich, S.K., Cheng, G., 2018. Human-agent co-adaptation using error-related potentials. *J. Neural Eng.* 15, 066014. <https://doi.org/10.1088/1741-2552/aae069>
- [34] Compston, A., 2010. The Berger rhythm: potential changes from the occipital lobes in man, by E.D. Adrian and B.H.C. Matthews (From the Physiological Laboratory, Cambridge). *Brain* 1934: 57; 355–385. *Brain* 133, 3–6. <https://doi.org/10.1093/brain/awp324>
- [35] Miranda, E.R., Brouse, A., 2005. Interfacing the Brain Directly with Musical Systems: On Developing Systems for Making Music with Brain Signals. *Leonardo* 38, 331–336. <https://doi.org/10.1162/0024094054762133>
- [36] Chew, Y.C. (Denise), Caspary, E., 2011. MusEEGk: a brain computer musical interface, in: Proceedings of the 2011 Annual Conference Extended Abstracts on Human Factors in Computing Systems - CHI EA '11. Presented at the the 2011 annual conference extended abstracts, ACM Press, Vancouver, BC, Canada, p. 1417. <https://doi.org/10.1145/1979742.1979784>

Sažetak

Rješavanje klasifikacijskih problema iz snimaka elektroencefalograma kod sučelja između mozga i računala

U ovom radu su opisani i objašnjeni najvažniji pojmovi vezani uz sve dijelove sučelja mozga i računala. Kratkim prolazom kroz neuroznanost predviđena je fiziologija mozga, morfologija signala EEG-a te komponente koje su kasnije detektirane i klasificirane metodom strojnog učenja, tj. dubokog učenja. Za klasifikaciju su odabранe konvolucijske neuronske mreže koje bi u teoriji mogле same naučiti važne značajke i samim time olakšati cijelokupnu analizu. Za arhitekturu ove mreže je korišten model EEGNet koji je pokazao dobre rezultate s obzirom na svoju plitkost. Ispitivane su dvije vrste evociranih potencijala, P300 i ERN na pridruženim skupovima podataka. U svakoj analizi ispitane su sposobnosti modela prilikom učenja na tri načina; prijenosom između ispitanika, izgradnjom individualnih klasifikatora po ispitaniku te jednog generalnog. Ova arhitektura se nije pokazala kao najbolja za potrebe učenja prijenosom, iako je davala solidne rezultate za skup podataka ERN.

Ključne riječi: BCI, EEG, elektroencefalogram, strojno učenje, konvolucijske neuronske mreže, biomedicina

Summary

Solving Classification Problems from Electroencephalogram Recordings in Brain-Computer Interfaces

In this work the most important terms for each part of the brain computer interface have been described. With brief run through neuroscience, short overview of the physiology of the human brain as well as morphology of the EEG signal and its components have been presented. These components were later classified with the use of machine learning, or concretely deep learning algorithms. For classification, convolutional neural networks have been chosen because of their ability to automatically construct features from the raw signals. The specific architecture used in this analysis was based on the model called EEGNet which has proved itself with good results despite its shallow architecture. In the analysis, the model was applied to two different datasets, one where the ERN component has been analysed and in the other audio evoked P300 component has been analysed. For each dataset, model's abilities have been tested in three ways; cross subject learning, individual subject based learning and general model. This architecture didn't prove itself to produce best results for cross subject learning, but it still achieved respectable results on the ERN dataset.

Keywords: BCI, brain computer interface, EEG, electroencephalography, machine learning, convolutional neural network, biomedicine