Sučelje mozak - računalo za pisanje primjenom auditornih podražaja

Markovinović, Ivan

Doctoral thesis / Disertacija

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Engineering / Sveučilište u Rijeci, Tehnički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:190:612506

Rights / Prava: Attribution 4.0 International/Imenovanje 4.0 međunarodna

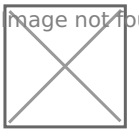
Download date / Datum preuzimanja: **2024-03-29**



Repository / Repozitorij:

Repository of the University of Rijeka, Faculty of Engineering





SVEUČILIŠTE U RIJECI
TEHNIČKI FAKULTET

Ivan Markovinović

SUČELJE MOZAK–RAČUNALO ZA PISANJE PRIMJENOM AUDITORNIH PODRAŽAJA

DOKTORSKI RAD

Rijeka, 2022.

SVEUČILIŠTE U RIJECI
TEHNIČKI FAKULTET

Ivan Markovinović

SUČELJE MOZAK-RAČUNALO ZA PISANJE PRIMJENOM AUDITORNIH PODRAŽAJA

DOKTORSKI RAD

Mentor: Prof. Dr. Sc. Saša Vlahinić
Komentor: Prof. Dr. Sc. Miroslav Vrankić

Rijeka, 2022.

UNIVERSITY OF RIJEKA
FACULTY OF ENGINEERING

Ivan Markovinović

AUDITORY BRAIN-COMPUTER INTERFACE SPELLER

DOCTORAL THESIS

Rijeka, 2022.

Mentor: Prof. dr. sc. Saša Vlahinić, Sveučilište u Rijeci, Hrvatska, Tehnički fakultet

Komentor: Prof. dr. sc. Miroslav Vrankić, Sveučilište u Rijeci, Hrvatska, Tehnički fakultet

Doktorski rad obranjen je dana 01.03.2023 na Tehničkom fakultetu Sveučilišta u Rijeci, pred povjerenstvom u sastavu:

1. Doc. dr. sc. Ivan Volarić, Tehnički fakultet, Sveučilište u Rijeci
2. Prof. dr. sc. Viktor Sučić, Tehnički fakultet, Sveučilište u Rijeci
3. Doc. dr. sc. Peter Rogelj, University of Primorska; Faculty of Mathematics, Natural Sciences and Information Technologies, Slovenia

Posvećeno mojoj obitelji.

Zahvala

Rezultati dobiveni u ovom doktorskom radu ne bi bili mogući bez sati i sati provedenih u laboratoriju i dragih osoba koje su bile voljene izdvojiti svoje dragocjeno vrijeme i sudjelovati u eksperimentima. Iz tog razloga moje velike zahvale idu svima koji su barem jednom nosili „kapicu na glavi“, a posebno hvala ide za moje prijatelje i kolege Dr. Sc. Marka Perčića, Maju Dundović, Doc. Dr. sc. Ivana Volarića i Josipa Jurasića. Hvala Vam na super obavljenim mjerenjima i rezultatima, koordiniranju i usmjeravanju, glupim forama, sugestijama, potpori i naravno uvijek dobroj zezanciji uz kavu i cigaru.

Posebno hvala mom kolegi Zoranu Šverku koji je bio izvrstan suradnik, sugovornik i osoba od povjerenja.

Međutim najveće zahvale idu mojoj obitelji kojoj sam i posvetio ovaj doktorski rad, a posebno mojoj supruzi Mateji koja je bila najveća potpora i podrška u trenutcima kada je bilo najteže.

Sažetak

Kompletan gubitak motoričkih sposobnosti uzrokovan pretrpljenim traumatičnim događajem ili kao posljedica neurodegenerativne bolesti poput amiotrofične lateralne skleroze gotovo uvijek se manifestira kroz gubitak sposobnosti komunikacije, u pismu kao i govoru, što povrh svega dodatno pogoršava kvalitetu života pogođenih pojedinaca. Uz uvjet funkcionalnog organa vida, asistivna tehnologija ponudila je cijeli niz tehnoloških rješenja koja su navedenoj populaciji omogućila sposobnost komunikacije, te time poboljšala kvalitetu njihovog života. Unatoč dobrim rezultatima i širokom izboru mogućnosti takvi vizualni sustavi nisu primjenjivi za malu grupu osoba kod kojih je napredak bolesti uzrokovao gubitak vida. Problem komunikacije s takvim osobama još je uvijek otvoreno pitanje, gdje trenutna rješenja daju veoma limitirane rezultate.

Potencijalno rješenje nudi se kroz primjenu sučelja mozak-računalo odnosno sustava koji izmjerenu i obrađenu neurološku aktivnost pretvara u kontrolne naredbe za upravljani sustav. Većina dosadašnjih izvedbi sučelja koristi neurološku reakciju na vizualne podražaje ili neki oblik vizualne podrške s ciljem lakšeg upravljanja sustavom, čime je ova vrsta komunikacije također ograničena na osobe koje imaju sposobnost vida. U ovom doktorskom radu prezentirano je sučelje mozak-računalo za pisanje koje primjenjuje samo auditorne podražaje, a koje je namijenjeno navedenoj grupi čija se neurološka aktivnost mjeri najrasprostranjenijom i cjenovno najprihvatljivijom elektroencefalografskom (EEG) metodom. Temeljna ideja sustava je da korisnik na temelju klasificirane mjerene moždane aktivnosti izdvoji željeno slovo iz niza nasumično poredanih odabranih slova hrvatske abecede prezentiranih korisniku preko auditornih podražaja. Odabir stimulacija u obliku slova tj. fonema iz hrvatskog jezika omogućilo je izvedbu sustava koji pisanje ostvaruje redanjem slova, tj. na način koji je svima poznat zbog čega je upoznavanje i prilagodba na sustav maksimalno skraćena i dodatno prilagođena krajnjim korisnicima.

Obrada i analiza neuroloških reakcija izmjerenih na grupi subjekata prilikom korištenja predloženog sučelja pokazala je stabilne karakteristične moždane reakcije na ciljane podražaje, a isti podatci korišteni su za treniranje različitih tipova klasifikatora i prostornih filtera. Validacija sustava izvršena je na istim subjektima kroz zadatak pisanja rečenica, te je pokazala izvrsne i dobre rezultate kod 50% subjekata, dok konačna izvedba sustava obuhvaća obradu i klasifikaciju mjerenih EEG signala u stvarnom vremenu u dvije klasifikacijske razine. U prvoj razini subjektu su prezentirana sva odabrana slova hrvatske abecede, dok je povećanje točnosti

klasifikacije moguće kroz sljedeću klasifikacijsku razinu u kojoj se subjekt stimulira s pet slova s najboljim klasifikacijskim rezultatima iz prethodne razine.

Ograničenja primijenjene EEG mjerne metode i obrade signala pokazana su u analizi točnosti sustava s reduciranim brojem korištenih elektroda. Dobiveni rezultati zadržavaju postignutu točnost unatoč reduciranom broja elektroda pogotovo kod osoba koje navedeni sustav koriste s velikom sigurnošću, ukazujući pritom na veliki nedostatak prostorne rezolucije kod EEG mjerenja i potrebu za primjenom mjernih metodama boljih prostornih karakteristika.

Ključne riječi: obrada EEG signala, sučelje mozak-računalo, auditorni podražaji

Abstract

The complete loss of motor skills caused by the suffered traumatic event or as a result of neurodegenerative disease such as amyotrophic lateral sclerosis, almost always manifests itself through inability to communicate, both in writing and speech, which further degrades the life quality of the individuals in question. In case of a patient's functional eyesight, the assistive technology offered a whole series of technological solutions which restore the communication capability of the mentioned population, increasing their life quality. Despite good results and a wide selection of options, such systems are not suitable for a small group of people who experienced vision loss in the advanced stages of diseases. Problem of communicating with such individuals remains the open topic, where current solutions provide very limited results.

A potential solution is available through the application of a brain-computer interface, i.e. a system which converts the measured and processed neurological activity into control commands for the managed system. Large number of such interfaces use a neurological reaction to visual stimuli or use some form of visual support in order to simplify the control of the system, hence this type of interface is also limited to individuals with eyesight. This doctoral thesis proposes brain-computer interface for writing that applies only auditory stimuli, and which is intended for the mentioned group whose neurological activity is measured by the most widespread and affordable method: Electroencephalogram (EEG). The basic idea behind the proposed system is that the user selects the desired letter from a series of randomly ordered letters of the Croatian alphabet presented through the auditory system based on the classified measured brain activity. The selection of stimuli in the form of letters, that is, phonemes from the Croatian language enabled the implementation of a spelling system maximally shortening the end-user training time.

Processing and analysis of neurological reactions measured on a group of subjects with the proposed interface showed stable typical brain reactions to target stimuli, and the same data has been used to train several types of classifiers and spatial filters. Validation of the system has been performed on the same group of subjects through the task of writing sentences, showing a satisfactory result in 50% of subjects. The final system implementation includes processing and classification of measured EEG signals in real time across two classification levels. In the first level, all included letters are presented to the subject once, while the second classification level further increases the classification accuracy by stimulating the subject with additional five letters which achieved the highest classification probability in the previous stage.

The limitations of the proposed EEG measurement and processing method is shown in the analysis of the system accuracy with the reduced number of used electrodes. The obtained results indicate a similar system accuracy with the reduced number of electrodes, especially by subjects who are able to use proposed system with great confidence, indicating a deficiency in the spatial resolution of the EEG measurement which can be solved by using measuring methods with better spatial characteristics.

Keywords: EEG signal processing, Brain Computer – Interface (BCI), auditory stimulation

Sadržaj

Zahvala **xi**

Sažetak **xii**

Abstract **xiv**

1. Uvod **1**

1.1. Znanstvena motivacija ... 1

1.2. Ciljevi doktorskog rada ... 2

1.3. Znanstveni doprinos ... 3

1.4. Organizacija doktorskog rada ... 4

2. Pregled stanja literature **7**

2.1. Sučelje mozak-računalo ... 7

2.2. Pregled stanja tehnologije ... 17

3. Sučelje mozak-računalo za pisanje – eksperimentalna paradigma **23**

3.1. Eksperimentalna paradigma ... 23

3.2. Implementacija eksperimentalne paradigme ... 26

3.2.1. Acquisition Client ... *27*

3.2.2. Generate Stimuli ... *27*

3.2.3. Keyboard stimulator ... *29*

3.2.4. Sound Player ... *29*

3.3. Metode klasifikacije mjerene neurološke reakcije ... 30

3.3.1. xDAWN prostorni filter ... *30*

3.3.2. Metoda potpornih vektora ... *32*

3.3.3. Konvolucijska neuronska mreža ... *33*

4. Rezultati analize eksperimentalnih mjerenja **35**

4.1. Provedba eksperimentalnih mjerenja ... 35

4.2. Analiza nezavisnih komponenti ... 38

4.3. Obrada mjerenih signala neurološke aktivnosti ... 41

4.4. Rezultati mjerenja eksperimentalne paradigme s povratnom informacijom ... 43

4.5. Rezultati mjerenja eksperimentalne paradigme bez povratne informacije ... 55

5. Sučelje mozak-računalo za pisanje – validacija sustava **61**

5.1. Rezultati treniranja klasifikatora 61
5.1.1. xDAWN + SVM 61
5.1.2. Konvolucijska neuronska mreža 64
5.2. Rezultati validacije sučelja mozak-računalo za pisanje 66
5.3. Modifikacija sučelja mozak-računalo 70
5.4. Rezultati validacije sučelja mozak-računalo za pisanje u dvije klasifikacijske razine 72
5.5. Analiza utjecaja smanjenja broja elektroda na točnost sučelja mozak-računalo 77

6. Sučelje mozak-računalo za pisanje u stvarnom vremenu 83
6.1. Izvedba sustava u stvarnom vremenu 83
6.2. Rezultati korištenja sučelja mozak – računalo za pisanje u stvarnom vremenu 89

7. Zaključak 97

Popis referenci 101

Popis simbola 111

Popis skraćenica 113

Popis slika 115

Popis tablica 121

Životopis 123

1. Uvod

1.1. Znanstvena motivacija

Sposobnost komunikacije neovisno o tome radi li se govoru ili pismu neizostavan je aspekt čovjeka kao društvenog bića, iako je navedena sposobnost najčešće uzeta zdravo za gotovo. Kompleksnost komunikacije osigurala je izmjenu velikih količina informacija i znanja među ljudima i uvelike doprinijela napretku ljudske vrste. Iz navedenog, jasno je da gubitak komunikacije s okolinom može predstavljati veliki gubitak i značajno degradirati kvalitetu života pogođene osobe.

Ovisno o tipu i stadiju bolesti, asistivna tehnologija ponudila je mnogobrojna tehnička rješenja koja su omogućila upravljanje računalom i kroz djelomično osamostaljenje povećala kvalitetu života korisnika. Primjerice, upravljanje pokazivačem računala uz minimalne pokrete mišića usana odnosno udisanjem i izdisanjem kroz specijalizirani uređaj ili pomicanjem fokusa očiju na segment ekrana od interesa. Pomicanje očiju registrira se kamerama priključenim za upravljano računalo na temelju čega upravljački algoritam računa željene koordinate pokazivača. Unutar iste grupe sustava koji olakšavaju život osobama s potrebama spadaju i sučelja mozak-računalo čiji je zadatak mjerenjem moždane aktivnosti omogućiti upravljanje različitim elektro-mehaničkim sustavima odnosno omogućiti interakciju s okolinom bez motoričkih radnji. Navedeno je samo djelomično točno iz razloga što većina sučelja mozak – računalo stimulira subjekte vizualnim podražajima za čije je uspješno korištenje potrebna funkcionalna sposobnost vida s mogućnošću usmjeravanja fokusa. Veća točnost, značajno manja cijena sustava, robusnost korištenja i brzina prijenosa informacija kod prethodno istaknutih sustava naspram sučelja mozak-računalo uvjetovala je korištenje sučelja pretežno u znanstveno-istraživačke svrhe.

Unatoč kvalitetnim rezultatima koje navedeni asistivni sustavi mogu ostvariti glavni uvjet korištenja: funkcionalnost vida, nije uvijek zadovoljen kod svih osoba s posebnim potrebama. To je posebno istaknuto kod osoba s oštećenim vidom i paralizom uslijed traume glave ili koje boluju od neurodegenerativnih bolesti kao što je amiotrofična lateralna skleroza (engl. *Amyotrophic Lateral Sclerosis*, ALS) u kojoj propadanjem neurona u regijama za kontrolu mišića dolazi do progresivnog gubitka mišićne kontrole što uključuje i mišiće očiju u kasnijim stadijima bolesti. Moguće rješenje za navedenu grupu pacijenata predstavljaju sučelja mozak-računalo koji primjenjuju auditorne podražaje kao sredstvo generiranja neuroloških reakcija

čijom se obradom i klasifikacijom računaju potrebne upravljačke naredbe.

Upotreba auditornih stimulacija u sučeljima pokazala je nekoliko značajnih nedostataka koje su utjecale na točnost, a samim time korisnost i upravljivost sustava. Prvi nedostatak je slabiji neurološki odziv na stimulaciju kod auditornih u usporedbi s vizualnim podražajima čime je dodatno narušen već ionako slab omjer korisnog mjerenog signala povezanog sa stimulacijom i pozadinske moždane aktivnosti koja je rezultat ostalih paralelnih neuroloških procesa. Drugi problem se odnosi na brzinu stimuliranja subjekta, gdje u slučaju vizualnih podražaja imamo mogućnost korištenja veće frekvencije stimuliranja. Brzim stimuliranjem subjekta moguće je prikupiti više neuroloških odziva na istovjetne stimulacije i temeljem redundantnih informacija istaknuti evocirane neurološke reakcije i poboljšati točnost sučelja. Sve navedeno utjecalo je na to da se u dosadašnjim izvedbama sučelja mozak-računalo s auditornim stimulacijama pored zvučnih koriste i vizualne stimulacije ili barem vizualna asistencija, dok je primjena samo auditornih podražaja dosada rezultirala vrlo malim točnostima i posljedično vrlo malom brzinom prijenosa informacija, ostavljajući pitanje komunikacije ciljane grupe subjekata još uvijek otvorenim.

1.2. Ciljevi doktorskog rada

Dosadašnje izvedbe sučelja mozak-računalo za pisanje s auditornim stimulacijama kako je već opisano u prethodnom poglavlju, koriste vizualnu pomoć prilikom korištenja sustava. Na taj način kompleksnost pisanja preusmjerena je sa stimulacija koje su maksimalno pojednostavljene (stimulacija nema nikakvu intuitivnu vezu sa govorom ili pismom) na arhitekturu sučelja koja predstavlja vezu između stimulacija i samog procesa pisanja. Unatoč vrlo dobrim ostvarenim točnostima na zdravim osobama, navedeni sustavi imaju nepremostiv nedostatak koji kompletno isključuje korištenje predloženih sučelja mozak-računalo kod ciljanih krajnjih korisnika. S ciljem prevladavanja navedenog problema u ovom doktorskom radu predložena je eksperimentalna paradigma s auditornim podražajima u obliku slova tj. fonema iz hrvatskog jezika koja će služiti kao osnova arhitekture sučelja mozak-računalo za pisanje. Odabirom stimulacija koje su direktno povezane s jezikom odnosno pisanom komunikacijom, olakšan je postupak prezentiranja sustava i maksimalno skraćeno početno privikavanje korisnika na predloženi sustav. Nedostatak primijenjenih stimulacija je njihova kompleksnost u usporedbi s dosadašnjim korištenim auditornim podražajima, zbog čega je vrijeme između dviju uzastopnih stimulacija nešto duže od uobičajenih dosadašnjih vrijednosti kako bi se korisniku osiguralo dovoljno vremena za analizu stimulacije i adekvatnu neurološku

reakciju, čime je sučelje dodano prilagođeno željenoj grupi osoba.

Na mjerenjima neurološke aktivnosti dobivenih primjenom elektroencefalografije (engl. *Electroencephalography*, EEG) uz korištenje predložene eksperimentalne paradigme, primijenjen je alat za obradu signala s ciljem izdvajanja komponenta neurološke aktivnosti povezanih s traženim reakcijama na ciljanu stimulaciju. Ista mjerenja korištena su za treniranje prostornih filtera i klasifikatora čiji je zadatak klasifikacija mjerenih i obrađenih neuroloških reakcija evociranih auditornim podražajima u dvije klase: ciljane i ne-ciljane stimulacije.

Validacija predloženog sučelja izvedena je na grupi subjekata uz zadatak pisanja rečenica, a konačni rezultat je izvedba sučelja mozak-računalo u stvarnom vremenu s dvije klasifikacijske razine u kojoj druga razina koristi najbolje klasifikacijske rezultate iz prethodne razine s ciljem povećanja konačne točnosti sustava. Navedena implementacija sustava testirana je na subjektima iz početne grupe koji su u prethodnim istraživačkim fazama ostvarili vrlo dobre rezultate u korištenju istog. Na istim subjektima provest će se analiza utjecaja smanjenja broja korištenih elektroda na konačnu točnost sustava. Navedenom analizom pokušati će se odgovoriti na pitanje mogućnosti smanjenja kompleksnosti i cijene sustava kao i dodatno pokazati ograničenja koju EEG akvizicija neuroloških signala predstavlja za implementirano sučelje mozak-računalo.

1.3. Znanstveni doprinos

Znanstveno istraživanje prezentirano u ovom doktorskom radu predstavlja doprinos u veoma izazovnom i tehnički zahtjevnom području obrade, analize i klasifikacije neuroloških reakcija mjerenih elektroencefalografijom s konačnim ciljem implementacije sučelja mozak-računalo za pisanje. U tu svrhu definirana je eksperimentalna paradigma koja se temelji na nizu od 22 slova tj. fonema iz hrvatskog jezika koji se u obliku auditornih podražaja u nasumičnom redoslijedu prezentiraju korisniku. Odabirom stimulacija i načinom pisanja rečenica sučelje je maksimalno prilagođeno krajnjim korisnicima, tako da je osigurana mogućnost lake prezentacije arhitekture sustava i vrlo brza prilagodba na korišteno sučelje. Dodatnu vrijednost istraživanju i prilagodbi sučelja mozak-računalo krajnjim korisnicima predstavlja primjena zatvorenih očiju tijekom korištenja sučelja, što nije bila dosadašnja praksa. Obrada i analiza EEG mjerenja dobivenih korištenjem predložene eksperimentalne paradigme izdvojila je stabilne neurološke signale povezane s odzivom na ciljanu stimulaciju, koji se u dobroj mjeri poklapaju s odzivima na ciljanu stimulaciju u sličnim implementacijama sučelja mozak-računalo.

Konačni rezultat izvedba je sučelja za pisanje u stvarnom vremenu koje se sastoji od dvije klasifikacijske razine čime je uz dodatnu prezentaciju stimulacija povećana točnost kod svih ispitanih subjekata. Prema konfiguraciji sučelja sustav „pokušava“ odgonetnuti traženo slovo unutar prve klasifikacijske razine odnosno prvog niza od 22 različita slova koja se putem auditornog sustava prezentiraju korisniku. U slučaju nedovoljno dobre klasifikacijske sigurnosti nakon prve razine dodatno poboljšanje točnosti ostvareno je primjenom opcionalne druge klasifikacijske razine. Unutar druge klasifikacijske razine predviđeno je ponavljanje stimulacija s najboljim rezultatima iz prethodne razine, nakon čega slijedi konačni odabir traženog slova. Odabrano slovo prezentira se korisniku nakon svakog segmenta, čime je osigurana povratna veza prema korisniku. Validacija predloženog sustava na subjektima pokazala je izvrsne rezultate kod dvoje subjekata, vrlo dobre rezultate kod još troje subjekta, dok je ostatak ostvario nedovoljno dobre rezultate, čime su predloženim sustavom ostvareni bolji rezultati od sličnih studija koje koriste sučelja s čisto auditornim podražajima. Konačna izvedba sustava kao opciju također podržava mogućost povratka na prethodno slovo u slučaju pogrešnog odabira, što je izvedeno usmjeravanjem fokusa na dodatnu POVRATAK stimulaciju koja je uključena u nasumični stimulacijski niz čime je prva klasifikacijska razina sada određena s ukupno 23 auditorne stimulacije. Korištenje navedene opcije pokazalo se kao vrlo potentna metoda, ali samo kod subjekata s vrlo velikom točnošću pisanja.

Ograničenja korištene EEG akvizicijske metode prikazana su u analizi utjecaja smanjenja broja korištenih elektroda na točnost pisanja. Za potrebe analize definirane su dodatne četiri reducirane konfiguracije s time da posljednja konfiguracija sadrži samo 30% ukupnog broja elektroda početne konfiguracije. Dobiveni rezultati ukazuju na vrlo malo smanjenje točnosti s redukcijom broja mjernih elektroda kod subjekata koje uspješno koriste sučelje, dok je kod osoba koje sučelje koriste s vrlo velikom točnošću navedena razlika gotovo neznačajna, što ukazuje na očite limite koje EEG metoda i njezina loša prostorna rezolucija ima u predstavljenoj konfiguraciji sučelja mozak-računalo.

1.4. Organizacija doktorskog rada

Doktorski rad organiziran je u sedam poglavlja od kojih svaki zasebno pokriva glavne segmente istraživanja. U prvom uvodnom poglavlju iznesena je znanstvena motivacija, glavni ciljevi, te znanstveni doprinosi rada. Drugo poglavlje započinje s pregledom trenutno dostupnih tehnika mjerenja moždane aktivnosti, s naglaskom na EEG kao mjernu tehniku korištenu u

ovom radu. U nastavku istog poglavlja prezentirane su glavne odlike i problematika sučelja mozak-računalo, a poglavlje je završeno s pregledom dosadašnjih radova na području sučelja mozak-računalo s auditornim podražajima. Treće poglavlje donosi pregled predložene eksperimentalne paradigme kao osnove sustava za pisanje, što uključuje glavne karakteristike, izvedbu i odabrane metode prostornog filtriranja i klasifikacije. Četvrto poglavlje započinje s kratkim opisom korištene EEG mjerne konfiguracije, te se nastavlja s pregledom neuroloških reakcija na ciljane i ne-ciljane stimulacije dobivene primjenom analize nezavisnih komponenti na pred-obrađene EEG signale. U sljedećem petom poglavlju prezentirani su rezultati treniranja i validacije korištenih klasifikatora, kao i rezultati pisanja rečenica u dvije iteracije. U prvoj iteraciji sustav je testiran na pet subjekata, a nakon dodatnih promjena u konfiguraciji predloženog sustava u sljedećoj iteraciji dodatnih pet subjekata uvedeno je u proces testiranja. Poglavlje je završeno analizom utjecaja smanjenog broja EEG elektroda na konačnu točnost sustava. Poučeni dobivenim rezultatima, razvijen je sustav za pisanje primjenom auditornih podražaja u stvarnom vremenu, čija je izvedba prezentirana u poglavlju šest zajedno s rezultatima pisanja riječi/rečenica na subjektima koji su ostvarili dobre rezultate u prethodnoj interakciji sa sustavom. Pregled ostvarenih rezultata kao i detaljan pregled zaključaka i daljnjih smjerova istraživanja koji bi mogli poboljšat svojstva predloženog sučelja prezentirani su u posljednjem sedmom poglavlju ovog rada.

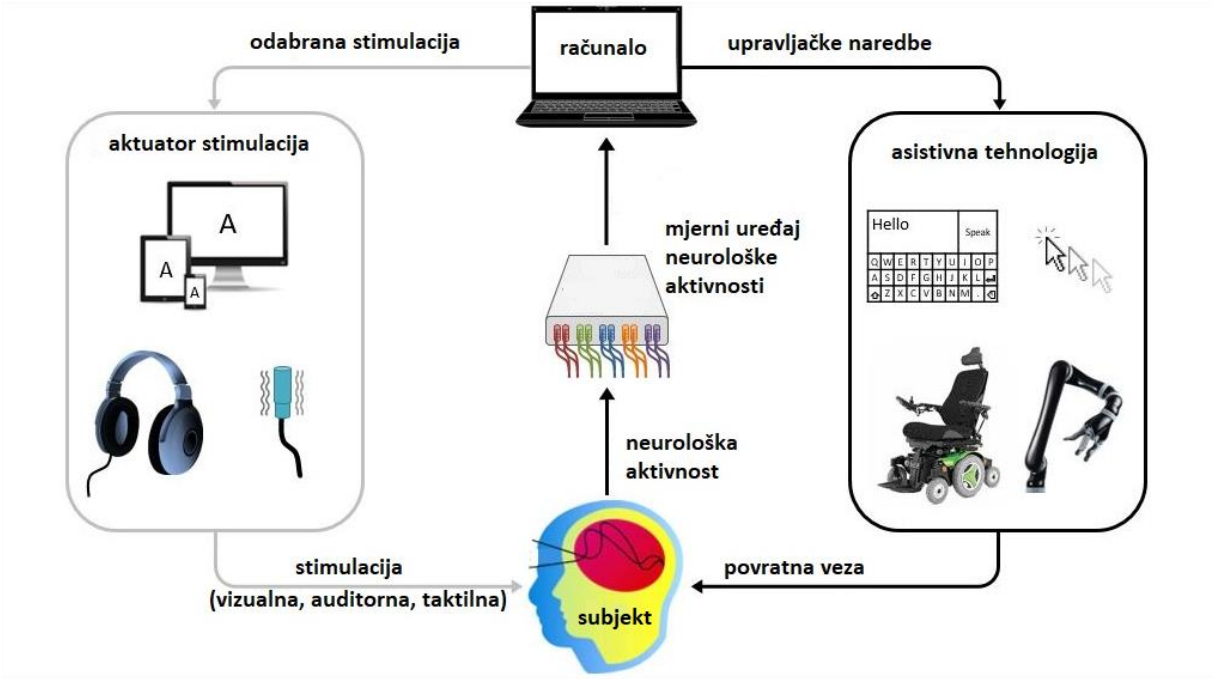
2. Pregled stanja literature

2.1. Sučelje mozak-računalo

Sučelja mozak-računalo (engl. *Brain Computer-Interfaces*, BCI), sustavi su projektirani s ciljem mjerenja neurološke aktivnosti subjekta te obrade i analize istih u svrhu interakcije i/ili komunikacije s okolinom [1]. Prvenstveno su navedeni sustavi namijenjeni osobama koji su uslijed pretrpljene traume ili napretka bolesti ostali potpuno nepokretni uz očuvanu sposobnost vida (engl. *Locked-in Syndrome*, LIS) odnosno bez mogućnosti korištenja očiju (engl. *Completely Locked-in Syndrome*, CLIS) u svrhu ostvarivanja komunikacije [2]–[4], međutim BCI sustavi primjenu su našli u rehabilitaciji [5], interakciji sa elektromehaničkim uređajima kao što su roboti i ortopedska pomagala [6], [7], odnosno u zabavne svrhe u običnoj interakciji sa računalom [8] ili videoigrama [9].

Osnovni element svakog BCI sustava, čija je standardna konfiguracija prikazana na slici 2.1. je uređaj za prikupljanje neurološke aktivnosti korisnika. Promatrajući samo neinvazivne metode s kojima se moždana aktivnost subjekta mjeri uređajima postavljenim na ili u blizini glave; s obzirom na način mjerenja neurološke aktivnosti akvizicijske uređaje moguće je podijeliti u dvije osnovne grupe. Prva grupa sastoji se od uređaja koji mjere električna odnosno magnetna polja uzrokovana gibanjem generiranih električnih naboja u mozgu subjekta kao što su EEG i magnetoencefalografija (engl. *Magnetoencephalography*, MEG), dok se druga kategorija odnosi na sustave koji neurološku aktivnost mjere kroz promjenu protoka krvi bogate kisikom u određenoj regiji mozga kao što su funkcionalna magnetna rezonanca (engl. *functional Magnetic Resonance Imaging*, fMRI) i funkcionalna bliska infracrvena spektroskopija (*functional Near-Infrared Spectroscopy*, fNIRS).

Najstariji i najčešće korišteni uređaj za mjerenje moždane aktivnosti je elektroencefalogram gdje su prva eksperimentalna mjerenja moždane aktivnosti na ljudima provedena davne 1924. godine. Današnji moderni EEG uređaji sastoje se od elektroda koje se postavljaju na skalp subjekta, te preciznih operacijskih pojačala i analogno-digitalnih pretvornika koji pojačavaju i digitalno uzorkuju signal amplituda nekoliko mirkovolti, kao i filtera za smanjenje utjecaja vanjskih smetnji na mjereni električni signal [10]. Prilikom najmanje aktivnosti mozga, neuroni koji predstavljaju osnovne građevne elemente našeg mozga, zbog različitog električnog potencijala uzrokovanog nakupljenim ionima na svojim membranama prilikom aktivacije generiraju električne signale koji ovisno o tipu moždane aktivnosti mogu potaknuti pojačanje



Slika 2.1. Prikaz standardnih konfiguracija sučelja mozak-računalo. Ovisno o tipu sučelja, u prvoj varijanti (lijeva strana) računalo generira vizualne, auditorne ili taktilne stimulacije u definiranim vremenskim intervalima te na temelju izmjerene i obrađene moždane aktivnosti sinkroniziranom sa stimulacijom određuje od strane korisnika ciljanu stimulaciju. U drugoj varijanti (desna strana) korisnik sam određuje potrebu za motoričkom radnjom, nakon čega se na temelju mjerene moždane aktivnosti definiraju parametri za upravljanje elektromehaničkim sustavima. Ovisno o zahtjevima sustava moguće je odabrati jednu ili kombinaciju više metoda za mjerenje moždane aktivnosti. Preuzeto sa [11].

odnosno generiranje novih sinkronih električnih signala kod ostalih povezanih neurona. U situaciji kada je neurološka aktivnost aktivirala veliku količinu neurona u određenoj subregiji mozga, tada generirani električni signali tvore električno polje čija je jakost dovoljna da između mjerne i referentne elektrode EEG akvizicijskog uređaja generira napon koji je proporcionalan promatranoj neurološkoj aktivnosti [12]. Analogno-digitalna pretvorba omogućava pretvaranje mjerenog napona u digitalni zapis čime je omogućeno povezivanje uređaja sa računalom. Tehnički gledano, velika prednost EEG uređaja je velika temporalna rezolucija odnosno brzina otipkavanja signala koja u modernim EEG uređajima pokriva područje od 100 Hz do 3 kHz. Povrh toga, postavljanje elektroda u današnjim uvjetima prilično je jednostavan i brz proces koji uz malu cijenu EEG uređaja i njegove male dimenzije odnosno mobilnost doprinosi pristupačnosti EEG uređaja u medicinske, istraživačke i BCI svrhe.

S druge strane primjena elektrolitskih gelova s ciljem redukcije električnog otpora između

mjerne elektrode i skalpa, može uzrokovati mjerenja slabije kvalitete u slučaju neispravnog nanošenja elektrolitskog gela ili u slučaju dugotrajnijih mjerenja u kojima zbog sušenja gela dolazi do gubitaka provodljivosti gela i povećanja električnog otpora. Veliki problem pri mjerenju moždane aktivnosti pomoću EEG uređaja također je detekcija električnih polja koji nisu direktno vezani uz moždanu aktivnost već su povezani s motoričkim radnjama. Pomicanje glave pomoću vratnih mišića, uporaba mišića lica i vilice ili mišića koji su zaduženi za pomicanje očiju uzrokuju električne signale značajnije viših amplituda od signala uzrokovanih neurološkom aktivnosti subjekta, čime je mjerena korisna moždana aktivnost prekrivena puno dominantnijim izvorima električnog polja [13]. Navedene promjene u EEG signalima nazivaju se artefakti, i razlog su zbog čega je pri mjerenjima česta praksa da subjekt tijekom cijelog eksperimenta mora biti miran uz minimalno pomicanje i zatvaranje očiju, što može imati negativan utjecaj na kvalitetu mjerenja kod dugotrajnijih eksperimenata. Moguće rješenje u uklanjanju artefakata uzrokovanih pomicanjem očiju ili lica, upotreba je jedne ili više dodatnih elektroda postavljenih na lice oko očiju (engl. *Electrooculogram,* EOG). Pomoću dodatnih elektroda moguće je mjerenje električnih signala direktno povezanih s pomicanjem mišića, čime se izmjerena dinamika uzrokovana mišićnim pokretima uklanja iz EEG signala [14], [15]. Druga mogućnost je upotreba algoritama za rastavljanje višedimenzionalnih sustava u nezavisne komponente (engl. *Blind Source Separation*, BSS) kao što su analiza osnovnih komponenti (engl. *Principal Component Analysis,* PCA) i analiza nezavisnih komponenti (engl. *Independent Component Analysis,* ICA). Primjena navedenih algoritama na EEG signal, ostvaruje dekompoziciju višedimenzionalnog signala u komponente od kojih neke predstavljaju dinamiku povezanu sa artefaktima. Analizirajući temporalna i/ili spektralna i prostorna svojstva dobivenih nezavisnih komponenti moguće je klasifikacijom izdvojiti komponente povezane s artefaktima koje se naknadno uklanjaju iz mjerenja. Opisani postupak osnova je za većinu alata za detekciju i uklanjanje artefakata i neispravnih dijelova mjerenja [16]–[18]. Prednost posljednje metode nad EOG-om je mogućnost uklanjanja ostalih bioloških (npr. smetnje uzrokovane radom srca, EKG) i umjetnih (npr. promjena kvalitete EEG signala zbog naglog povećanja otpora između skalpa i elektrode) artefakata, međutim kompleksnost i vrijeme trajanja algoritma čine ga nepovoljnim za BCI aplikacije u realnom vremenu.

Najveći nedostatak EEG uređaja je njegova loša prostorna rezolucija, odnosno loš omjer korisnog signala i ostale prisutne neurološke aktivnosti (engl. *Signal to noise ratio,* SNR) prvenstveno zbog interferencije električnih polja različitih izvora unutar samog mozga (engl. volume conduction) kao i velikog utjecaja lubanje na stvorena električna polja, čime je značajno ograničena lokalizacija izvora neurološke aktivnosti. Povrh toga, za generiranje dovoljno jakog

mjerljivog električnog polja kako je već napomenuto, potrebna je sinkrona aktivacija velikog broja neurona iste prostorne orijentacije s idealnim smjerom električnog polja okomitim na površinu korteksa odnosno lubanje subjekta. Samim time veći dio dinamičkog ponašanja uzrokovanog neurološkim reakcijama neće biti detektiran, zbog čega je upotreba EEG tehnike ograničena na mjerenje i promatranje neuroloških aktivnosti sa značajnim sinkronim i usmjerenim električnim reakcijama [19].

Mjerenje magnetnih umjesto električnih polja uzrokovanih sinkronom reakcijom neurona pomoću magnetometara položenih okolo glave subjekta princip je MEG tehnike. Manji utjecaj vanstanične moždane tvari, lubanje i skalpa na prigušenje magnetnih u odnosu na električna polja smanjit će broj neurona sa sinkronom reakcijom potrebnih za generiranje mjerljivog magnetnog polja, odnosno volumni prostor koji aktivni neuroni zauzimaju. Iz navedenog razloga, MEG metoda omogućava precizniju lokalizaciju izvora neurološke aktivnosti odnosno posjeduje bolja prostorna svojstva u usporedbi s EEG sustavima [19], [20]. Za razliku od EEG metode, izvore neurološke aktivnosti radijalne orijentacije tj. usmjerene okomito na površinu korteksa čija se magnetna polja većinom poništavaju unutar glave, nije moguće detektirati MEG sustavom. S druge strane tangencijalni generatori moždane aktivnosti prema elektromehaničkim zakonima generiraju magnetna polja okomita na površinu skalpa dovoljne jačine da mogu prodrijeti van glave [20], [21]. Unatoč navedenim ograničenjima svakako najveći nedostatak je velika cijena MEG uređaja kao i veliki prostor koji ovakav uređaj u velikoj većini slučajeva zahtijeva [22]. Sve navedeno čini MEG uređaje nepogodnim i rijetko korištenim u BCI aplikacijama [23], zbog čega je primjena ovakvih uređaja uglavnom ograničena na medicinsko-istraživačke svrhe.

Problem smanjene prostorne rezolucije kod EEG i MEG uređaja moguće je nadoknaditi primjenom fMRI ili fNIRS tehnike, čiji se princip mjerenja moždane aktivnosti zasniva na detekciji povećanja krvnog protoka u aktivne subregije mozga (engl. *Hemodynamic response*, HR). Prilikom moždane aktivnosti, neuronima koji sudjeluju u procesu aktivacije i generiranja električnih signala, potrebna je za nastavak normalnog obavljanja predviđenih operacija povećana dostava hranjivih materijala (npr. glukoze) i kisika. Navedena biološka potreba uzrokovat će promjenu omjera protoka između krvi obogaćene kisikom i krvi osiromašene kisikom unutar aktivne regije mozga (engl. *Blood-oxygen-level-dependent*, BOLD) [24], [25], koju navedeni sustavi mogu odrediti sa velikom preciznošću i prostornom razlučivošću.

Općenito MRI metoda, generira jaka magnetna polja i radiovalove kako bi prostorno orijentirala i energetski pobudila protone promatranog unutarnjeg organa, koji nakon prestanka djelovanja radiovalova pri povratku u originalno energetsko stanje ovisno o vrsti organa

emitiraju elektromagnetno zračenje različitih valnih duljina. Izmjereni elektromagnetni valovi koriste se kako bi se iz njih rekonstruirao oblik mjerenog organa [26]. U slučaju fMRI metode koriste se magnetna svojstva odnosno magnetna susceptibilnost hemoglobina, proteina u krvi koji je odgovoran za vezivanje i tranziciju kisika u sve stanice tijela pa tako i neurone. Naime krv bogata hemoglobinom na koji je vezan kisik ima dijamagnetična svojstva dok je magnetno svojstvo kisikom osiromašenog hemoglobina blago paramagnetično. Promjene u generiranim magnetnim poljima zbog navedenih magnetnih svojstva dva različita stanja hemoglobina moguće je odrediti MRI metodom čime je omogućena lokalizacija aktivnih regija mozga [24], [27]. Ovisno o zahtjevima, fMRI metodom moguće je lokalizirati aktivna područja u mozgu veličine nekoliko milimetara kubičnih kao i mjeriti aktivnosti duboko unutar mozga, pružajući značajnije veću prostornu rezoluciju u odnosu na prethodno navedene metode.

Za razliku od fMRI metode koja koristi različita magnetna svojstva hemoglobina, lokalizacija aktivnih regija mozga na temelju protoka krvi putem fNIRS metode temelji se na različitim elektromagnetnim apsorpcijskim svojstvima kisikom bogatog i siromašnog hemoglobina. Detaljnije promatrano fNIRS se sastoji od jednog ili više foto-transmitera koji su sposobni generirati svjetlost različitih valnih duljina u bliskom infracrvenom području (frekvencijsko područje između vidljive crvene svijetlosti valne duljine oko 700 nm i infracrvenog područja čija niža granična vrijednost valne duljine iznosi 10 μm), te fotoreceptora koji mjere količinu reflektirane svjetlosti, a postavljaju se oko glave u sličnoj konfiguraciji kao i elektrode kod EEG uređaja [28]. Emitirana svijetlost u bliskom infracrvenom području sposobna je penetrirati skalp i lubanju subjekta te osvjetliti subregije koje su blizu površine korteksa. Ovisno o razini kisika apsorpcijska svojstva krvi se mijenjaju, tako da krv bogata kisikom bolje apsorbira elektromagnetne valove valne duljine veće od 790 nm, dok je kod krvi siromašne kisikom prisutna bolja apsorpcija kod valnih duljina manjih od 790 nm. Lokalizacija aktivnih regija mozga temelji se na omjeru apsorbirane odnosno reflektirane svijetlosti različitih valnih duljina tj. omjeru oksidizirane i deoksidizirane krvi (BOLD) u pojedinoj regiji mozga [29]. S obzirom da emitirana elektromagnetna svijetlost ne može prodrijeti duboko u unutrašnjost mozga, kao i zbog ograničenog broja foto transmitera i receptora, fMRI ima puno bolju prostornu rezoluciju [30] međutim nedostaci navedeni u nastavku teksta čine fNIRS uređaje prikladnijim u BCI konfiguracijama.

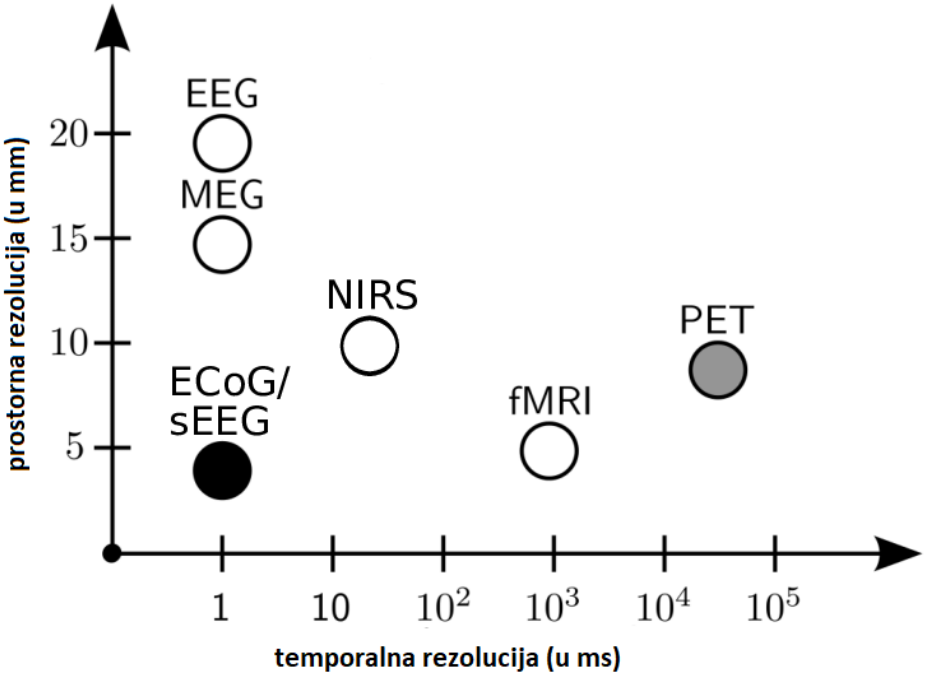
Općeniti nedostatak posljednje dvije navede metode je smanjena temporalna rezolucija u odnosu na EEG i MEG metodu, što može imati negativan utjecaj na broj informacija koje je u jedinici vremena moguće prenijeti sučeljem mozak-računalo. Razlog tome je kašnjenje koje se biološki javlja između povećane aktivnosti neurona i povećanog protoka krvi bogate kisikom.

Navedeno kašnjenje između podražaja i maksimalne vrijednosti izmjerenog BOLD signala otprilike iznosi 3-6 sekunde, a kompletna dinamika povezana s cijelim procesom aktivacije određene regije može trajati i do 30 sekundi. Opažena dinamička ograničenja posljedično će voditi ka povećanju vremenskog intervala između dvije stimulacije u BCI sustavu i/ili ka uporabi naprednih algoritama za rastavljanje višedimenzionalnih mjerenja u nezavisne komponente odgovorne za reakciju na pojedinu stimulaciju, što će uzrokovati smanjen protok informacija sučelja. Nedostatak vremenske razlučivosti moguće je kompenzirati kombiniranjem navedenih metoda sa EEG tehnikom [31], [32], kako bi se iskoristila odlična temporalna rezolucija kod mjerenja električne aktivnosti mozga.

Međutim glavna prednost fNIRS nad fMRI uređajima su cijena i izrazito male dimenzije gdje su izvedbe prijenosnih fNIRS mjernih sustava danas već industrijski standard, čime je svakako osigurana veća pristupačnost fNIRS uređaja u znanstvene i komercijalne svrhe. Osim navedenog fiksan položaj fNIRS senzora u odnosu na glavu subjekta omogućuje mjerenje moždane aktivnosti prilikom motoričke/fizičke aktivnosti, dok je kod fMRI mjerenja u većini slučajeva potrebna apsolutna mirnoća korisnika prilikom trajanja eksperimenta kako bi se smanjile distorzije u mjerenjima. Uz buku nastalu generiranjem magnetnih polja, zahtjev za minimalnim pomicanjem korisnika svakako može imati negativan utjecaj na upotrebu fMRI sustava u BCI aplikacijama.

Dosad predstavljene metode spadaju u kategoriju neinvazivnih metoda, te bi svakako valjalo spomenuti i dvije invazivne metode (engl. *intracranical Electroencephalograpy*, iEEG) koje su danas u središtu znanstveno-istraživačkog interesa. Prva metoda zasniva se na postavljanju 2D polja elektroda direktno na površinu korteksa (engl. *Electrocorticography*, ECoG) [33], dok je kod druge metode potrebna ugradnja zasebnih elektroda [33] ili polja elektroda [34] direktno u moždano tkivo. Oba sustava imaju veliku temporalnu rezoluciju sličnu EEG i MEG sustavima, ali izrazito bolju prostornu rezoluciju u usporedbi s ostalim sustavima kao što je vidljivo na slici 2.2. Glavni nedostatci invazivnih metoda je svakako velika tehnička i medicinska kompleksnost, a samim time i cijena koja prati ugradnju elektroda u najvažniji i najosjetljiviji dio ljudskog tijela, zbog čega je upotreba invazivnih metoda u BCI svrhe ograničena na tek nekoliko znanstveno-istraživačkih institucija.

Iz svega navedenog lako se može zaključiti kako je EEG mjerenje najčešće korišten i istražen tip mjerenja neurološke aktivnosti u BCI aplikacijama, dok u današnje vrijeme zbog brzog tehnološkog napretka sustavi koji neurološku aktivnost istovremeno mjere kombinacijom EEG i fNIRS metoda sve više postaju neizostavan dio istraživanja [35]. Definiranjem mogućih načina akvizicije neurološke aktivnosti potrebne za rad BCI sustava, sljedeći važan element iz



Slika 2.2. Prikaz temporalne i prostorne rezolucije dosad predstavljenih metoda akvizicije neurološke aktivnosti. Pored već spomenutih metoda, na slici je prikazana polu-invazivna pozitronska emisijska tomografija (engl. *Positron Emission Tomography*, PET) metoda koja koristi radioaktivni marker koji se ubrizgava subjektu kao sredstvo detekcije metaboličkih procesa odnosno s time povezana neurološka aktivnost.

konfiguracije BCI sustava prikazane na slici 2.1. svakako predstavlja mentalna strategija koja određuje tip neuroloških aktivnosti povezanih sa zadatkom ili stimulacijom koje sustav treba detektirati. Dosadašnji BCI sustavi uz primjenu EEG metode mjerenja baziraju se pretežno na dvije strategije: zamišljanje motoričkih radnji (engl. *Motor Imagery*) i strategija selektivnog fokusa (engl. *Selective Attention*). Ovisno o odabranoj mentalnoj strategiji sučelje odnosno računalo drukčije će pristupiti generiranju podražaja, obradi i klasifikaciji podataka izmjerene moždane aktivnosti.

Zamišljanje motoričkih radnji temelji se na mjerenju moždane aktivnosti senzorno-motorne regije mozga koja proizvodi oscilacije odnosno senzorno-motorne ritmove (engl. Sensory-motor rythms, SMR) u mjerenom EEG signalu na frekvencijama od 8-12 Hz (alfa područje EEG signala, μ-ritmovi) i 18-26 Hz (beta područje EEG signala, β-ritmovi). Istraživanja su pokazala smanjenje snage signala na definiranim frekvencijskim područjima (engl. *event-related desynchronisation*, ERD) prilikom pripreme za motoričku radnju ili zamišljanjem motoričkih pokreta. S druge strane prestanak zamišljanja pokreta ili relaksacija nakon motoričke radnje uzrokovat će porast snage signala odnosno sinkronizaciju signala na

promatranim frekvencijskim područjima (engl. *event-related synchronisation*, ERS) [36]. Međutim ERD i ERS nisu vezane samo uz motoričke ili senzorne radnje već je navedena promjena u snazi na definiranim frekvencijskim područjima prisutna i u ostalim dijelovima mozga te kod ostalih kognitivnih zadataka [1], o čemu će još riječi biti u četvrtom poglavlju ovog rada. Detekcija navedenih promjena u snazi signala omogućuje nekoliko tipova sučelja mozak-računalo, kao npr. upravljanje pokazivačem na monitoru u svrhu odabira „da“ ili „ne“ odgovora [37], upravljanje mehanizmom za otvaranje ili zatvaranja protetičke ruke [38], ili kao sustav za selekciju slova koji će omogućiti jednostavnu komunikaciju. Sustavi koji primjenjuju zamišljanje motoričkih radnji mogu se koristiti u subjektom uvjetovanoj BCI konfiguraciji u kojoj subjekt samoinicijativno (bez vanjske pobude) modulira svoje SMR signale koje sustav prepoznaje kao jednu od poznatih naredbi, kao na primjer BCI sustavi za pomicanje kursora na monitoru ili upravljanja ortopedskim pomagala. Navedeni sustavi moraju imati povratnu vezu kako bi se subjektu omogućila informacija o tome koliko je uspješan u modulaciji svojih signala pogotovo prilikom treniranja subjekta na korištenje BCI sustava. Upravljanje ovakvim sustavima podrazumijeva dugotrajno treniranje subjekta, gdje je duljina treniranja proporcionalna kompleksnosti sustava odnosno broju naredbi koje sustav podržava.

Nasuprot tome sustavi bazirani na selektivnoj pažnji, stimuliraju subjekta nizom stimulacija u obliku vizualnih [39], auditornih [40] ili taktilnih [41] podražaja, te na temelju izmjerene moždane aktivnosti direktno povezane sa stimulacijom (engl. *event-related potentials*, ERP) određuju ciljani podražaj na koji se subjekt fokusirao. Dvije vrste stimulacija odnosno generiranih neuroloških reakcija koriste se u navedenoj konfiguraciji selektivnog fokusa. U prvoj, koja je moguća samo sa vizualnim stimulacijama, subjektu se istovremeno prezentira više vizualnih stimulacija (složenost sustava odnosno broj mogućih naredbi određuje broj stimulacija) koje trepere različitim frekvencijama između 6-30 Hz. Fokusirajući svoju vizualnu pažnju prema ciljanoj stimulaciji, u okcipitalnoj regiji korisnikova mozga zaduženog za obradu vizualnih podražaja pojavljuju se frekvencijski stacionarni vizualnim podražajem evocirani potencijal (engl. *steady-state Visual Evoked Potential*, ssVEP) mjerljiv EEG uređajem čija je frekvencija titranja istovjetna ciljanoj vizualnoj stimulaciji [10]. Frekvencijskom analizom izmjerenog EEG signala moguće je odrediti ciljanu stimulaciju odnosno zatraženu naredbu. Primjena ssVEP signala u BCI svrhe, omogućila je nekoliko interesantnih sustava kao što je sustav za komunikaciju [42], sustav za upravljanje telefonskom brojevnom tipkovnicom [43] ili kao sustav za upravljanje protetičkom rukom [44].

Drugu mogućnost predstavlja P300 neurološka reakcija, gdje P u nazivu predstavlja pozitivan skok u amplitudi mjerenog signala dok se 300 odnosi na prosječan vremenski interval

izražen u milisekundama od trenutka prezentacije stimulacije do maksimalne vrijednosti mjerene električne aktivnosti. Opisana neurološka reakcija otkrivena je 60-ih godina prošlog stoljeća u vizualnom eksperimentu u kojem je osoba stimulirana sa dva tipa stimulacija, od kojih prva klasa predstavlja ciljane stimulacije odnosno brojeve čije opažanje prema eksperimentalnim uputama zahtijeva obavljanje daljnjih kognitivnog zadatka i drugom klasom stimulacija u obliku bljeskova čije opažanje od strane korisnika ne vodi ka daljnjim mentalnim akcijama [45]. Daljnja istraživanja provedena u istom desetljeću pokazala su obrnuto proporcionalnu povezanost amplitude P300 signala i vjerojatnosti pojavljivanja ciljane stimulacije [46], kao i mogućnost korištenja auditornih stimulacija u svrhu evociranja neuroloških reakcija s odzivima sličnim onima iz prijašnjih eksperimenta.

Opažene neurološke reakcije potaknule su cijeli niz novih istraživanja, ispitujući svojstva signala u eksperimentalnim paradigmama sa dvije (engl. *oddball*) ili tri (engl. *three-stimulus*) različite stimulacije. U oddball [47] paradigmama ciljana stimulacija s malom vjerojatnosti pojavljivanja u slučaju usredotočenosti subjekta na podražaje generira P300 reakciju u parietalnoj regiji mozga [48], za razliku od ne-ciljane stimulacije čija je vjerojatnost pojavljivanja puno veća. Tipičan zadatak koji subjekt mora obaviti prilikom ovakvih eksperimenta je pritiskanje tipke kako bi se neovisno mogla potvrditi reakcija subjekta na ciljanu stimulaciju. Iako su izvori P300 neurološke reakcije detaljnije utvrđeni primjenom fMRI metode [49], samo značenje P300 reakcije još uvijek je otvorena tema. Dosada prihvaćena pretpostavka je da P300 predstavlja inhibiciju selektivne pažnje s nadolazećih stimulacija odnosno preusmjeravanje pozornosti na ostale kognitivne procese povezane sa zadatkom čije obavljanje ciljana stimulacija zahtijeva. U navedenom eksperimentu nakon detekcije ciljane informacije i generiranja P300 signala, subjekt pristupa kratkoročnoj memoriji u frontalnim dijelovima mozga kako bi se prisjetio radnje koji ciljana stimulacija iziskuje. Prebacivanje dobivenih informacija o zadatku u temporalno-parietalne dijelove mozga koji su odgovorni za upravljanje senzorno-motoričkim radnjama rezultiraju u neurološkoj aktivnosti odgovornoj za pokretanje ruke i prsta odnosno pritiskanje tipke [50]–[52]. Dodatna istraživanja osim potvrde već dobro poznate obrnuto-proporcionalne ovisnosti amplitude P300 signala o vjerojatnosti pojavljivanja ciljane stimulacije, pokazala su ovisnost jačine (vidljivost/čujnost) i kompleksnosti stimulacije s generiranom P300 amplitudom. Prema [53] kompleksnije stimulacije koje zahtijevaju više analize od strane korisnika uvijek su rezultirale smanjenim amplitudama i povećanim kašnjenjima u P300 odzivu.

Dodavanje treće ometajuće (engl. *deflecting*) stimulacije sa sličnom vjerojatnošću pojavljivanja kao ciljana stimulacija, pored već prisutnih stimulacija (*three-stimulus paradigm*)

pokazala je dodatnu kompleksnost P300 signala. Naime kao i u odball paradigmi ciljana stimulacija uzrokuje P300 reakciju s već dobro poznatom prostorom distribucijom, ali značajnije slabijeg intenziteta, te je navedenoj reakciji dano novo ime P3b. Razlog tome je neurološka reakcija na ometajuću stimulaciju nazvana P3a s odzivom sličnim P300 reakciji, ali s drugačijom prostornom distribucijom koja je sada više usmjerena prema frontalnim regijama mozga [54], [55]. Korištenje P300 neurološke reakcije ima veliku prednost u BCI sustavima zbog svojeg malog kašnjenja i brze mogućnosti detekcije (P300 signal može se detektirati unutar EEG signala u trajanju od jedne sekunde nakon stimulacije) u usporedbi sa sustavima koji koriste zamišljanje motoričkih pokreta ili spore moždane potencijale (engl. *slow cortical potentials*, SPC) [1] što omogućava puno brži prijenos podataka. Povrh toga u usporedbi sa spomenutim sustavima potrebno je vrlo malo vremena za upoznavanje i prilagodbu subjekta na BCI sustav.

Najznačajnija upotreba P300 signala u BCI svrhe je sustav za komunikaciju odnosno sustav za pisanje P300 Matrix Speller [56], [57] koji se bazira na vizualnim stimulacijama. Navedeni sustav sastoji se od 6x6 matrice s 26 slova engleske abecede i znamenkama od 0 do 9, a čiji redci i stupci naizmjence u nasumičnom redoslijedu kratko zasvijetle. Korisnikov zadatak je usmjeravanje fokusa na željeno slovo, generirajući tako P300 reakciju svaki put kada se ciljano slovo nalazi unutar osvjetljenog retka i stupca. Analizirajući dio EEG signala nakon svake stimulacije sustav određuje redak i stupac sa najvećom vjerojatnošću da se u njima nalazilo ciljano slovo, koje je određeno njihovim presjecištem. Navedeni sustav omogućuje brz prijenos informacija i veliku točnost koristeći mali vremenski interval između dvije stimulacije (oko 150 ms) za kompenzaciju malog omjera korisnog signala i smetnje kod EEG mjerenja. Zbog velike brzine stimulacije u veoma kratkom vremenu svaki redak i stupac se mogu osvijetliti nekoliko puta generirajući tako veliki broj redundantnih mjerenja na istovjetne podražaje čijim je usrednjavanjem moguće istaknuti P300 reakciju. Tijekom godina nove metode obrade signala kao i napredak u vizualizaciji stimulacija omogućile su dodavanje novih naredbi koje sustav može prepoznati kao i povećanje brzine prijenosa informacija [58]–[60], čineći predloženu paradigmu korisnom i kod osoba koje su još u ranijim stadijima neurodegenerativnih bolesti kao što je ALS [61].

Veliki nedostatak P300 Matrix Speller sustava je ovisnost o fokusu subjekta na ciljane stimulacije (prilikom osvjetljavanja redaka i stupaca matrice važno je da subjekt gleda ciljano slovo ili broj), smanjujući efikasnost sustava kod osoba koje imaju problem sa pomicanjem očiju odnosno usmjeravanjem svojeg fokusa [62]. Imajući na umu sustave za praćenje pokreta očiju [63] koji daju puno više mogućnosti u upravljanju i interakciji s okolinom, BCI sustavi

koji se temelje na vizualnim stimulacijama koriste se prvenstveno u istraživačke svrhe. Međutim u situacijama kada je osoba doživjela tešku traumu mozga ili u situaciji već napredovalog stadija ALS-a u kojoj dolazi do disfunkcije motorike očiju [64], uporaba P300 sučelja mozak-računalo kod ciljane grupe osoba moguća je primjenom auditornih podražaja [65]–[68].

2.2. Pregled stanja tehnologije

Prvo P300 sučelje mozak-računalo s auditornim podražajima [65] sastoji se od četiri različite stimulacije: „YES“, „NO“, „PASS“ i „END“, od kojih samo prve dvije predstavljaju moguće odgovore na jednoznačno pitanje postavljeno od strane voditelja mjerenja. Posljednje dvije stimulacije predstavljaju „dummy“ stimulacije čiji je zadatak povećati omjer ciljane i ne-ciljanih stimulacija kako bi se povećala razlika u P300 odzivu na dvije klase korištenih podražaja. Svako mjerenje sastoji se od 25 ciljanih i 75 ne-ciljanih stimulacija koje se putem auditornog sustava prenose subjektu u intervalu od 1400 ms. Dvije grupe subjekata sudjelovale su u mjerenjima, gdje je prva grupa sastavljena od tri zdrave osobe, a druga od tri osobe sa već odmaklim stadijem ALS-a. Prosječna točnost u deset sesija varirala je između 50 - 70% kod prve grupe i 35 – 80% kod druge grupe subjekata.

Veliki uspjeh P300 Matrix Speller s vizualnim stimulacijama naveo je Klobassu i suradnike [69] na implementaciju BCI sustava s identičnom strukturom uz primjenu auditornih podražaja. Kao i u slučaju vizualnog sustava slova engleske abecede raspodijeljena su u matricu 5x5 (izostavljeno je slovo Z) čiji su redovi numerički označeni indeksima 1 - 5 od gore prema dolje, a stupci brojevima 6 - 10 s lijeva prema desnom kraju matrice. Sustav u nasumičnom redoslijedu s brzinom od 1.6 stimulacije u sekundi (interval između stimulacija: 625 ms) prezentira subjektu u sekvencama indekse putem auditornog sustava, gdje se generiranje P300 signala očekuje svaki put kada se ciljano slovo nalazi u retku ili stupcu određenim izgovorenim indeksom. Selekcija jednog slova vrši se kroz 15 sekvenci u trajanju od 6.25 sekunde što uz dodatnih 3.75 sekunde pauze radi preusmjeravanja pažnje na sljedeće ciljano slovo čini ukupno 97.5 sekundi. Mjerenja provedena na 13 subjekata pokazala su dobre rezultate kod većine subjekata, gdje je pet subjekata ostvarilo točnost između 80% i 100%, drugih pet subjekata ostvarilo je točnost između 60% i 80%, dok kod ostatka grupe nije bilo moguće ostvariti komunikaciju zbog male točnosti između 0% i 35%. Iako je većina subjekata ostvarila dobru točnost, brzina protoka informacija (engl. *Inter-Transfer Rate, ITR*) koje se predloženim sučeljem može ostvariti je

prilično mala i iznosi u najboljem slučaju 2.85 bita/min, odnosno 1.48 bita/min u prosjeku. Poboljšanje *ITR*-a dobiveno je daljnjom analizom u kojoj je za svakog subjekta uzet optimalan broj sekvenci s kojima je moguće dobiti barem 70% točnosti, čime je ostvarena prosječna i maksimalna vrijednost od 4.48 bita/min odnosno 12.37 bita/min. U istom istraživanju, provedena je usporedba opisanog sustava s identičnim sustavom koji koristi vizualne stimulacije nad istim subjektima i vremenskim intervalom od 125 ms između stimulacija. S takvim sustavom, samo dva subjekta ostvarila su rezultate od 75% dok je ostatak grupe ostvario rezultate između 95% i 100%. Povrh toga zbog povećane točnosti i smanjenog trajanja sekvence (1.87s) ostvaren je puno veći protok informacija gdje se postignuti *ITR* nalazi u intervalu između 4.37 bita/min (75% točnosti) i 7.55 bita/min (100% točnosti) u slučaju analize svih 15 sekvenci ili 9.48 bita/min i 22.28 bita/min u slučaju analize optimalnog broja sekvenci. Dobiveni rezultati ukazuju na dva velika nedostataka BCI sustava s auditornim u usporedbi s vizualnim podražajima. Prva je duljina trajanja intervala između dvije auditorne stimulacije koja je u usporedbi s vizualnim sustavom pet puta dulja, što samo po sebi označava pet puta manji *ITR*. Povrh toga, predloženi interval između dvije uzastopne stimulacije duljine 625ms dobro funkcionira kod zdravih subjekata, međutim za uporabu navedenog sustav u CLIS okruženju vjerojatno je potrebno povećati interval na jednu ili kao u prethodnom eksperimentu na 1.4 sekunde dodatno limitirajući brzinu sustava. Duljina intervala indirektno će negativno utjecati i na točnost sustava zbog smanjene količine informacija odnosno sekvenci koje sustav u istom vremenskom intervalu može izmjeriti, limitirajući tako količinu informacija za klasifikaciju ciljane stimulacije. Drugi problem je očita razlika u generiranoj P300 neurološkoj reakciji odnosno smanjena SNR vrijednost kod auditornih sustava, uzrokujući za istu količinu prikupljenih EEG mjerenja na 13 subjekata u prosjeku 30% nižu točnost. Dodatnu potvrdu varijabilnosti auditorne P300 reakcije potvrđuje vremenski interval između stimulacije i maksimalne P300 reakcije koja u slučaju auditornih sustava poprima vrijednosti između 400 i 950 ms (srednja vrijednost, M: 573 ms; standardna devijacija, STD: 194 ms), dok je kod vizualnih stimulacija kašnjenje P300 signala bilo bliže teoretskoj vrijednosti od 300 ms, između 250 ms i 450 ms (M: 350 ms; STD: 83 ms).

U sličnom istraživanju [40] po jedan redak i stupac originalne 6x6 matrice određeni su sa istom stimulacijom, tako da se u procesu selekcije slova koristi šest različitih distinktivnih zvukova (zvono, zujanje, …). U prvoj fazi kroz osam iteracija prezentirane stimulacije predstavljaju stupce matrice (ukupno 48 stimulacija), dok u drugoj fazi također u osam iteracija stimulacije predstavljaju retke matrice. Korištenje nešto jednostavnijih stimulacija omogućilo je vremenski interval između stimulacija od 500 ms. Deset subjekta sudjelovalo je u

istraživanju, gdje je prva polovica subjekata stimulirana samo auditornim podražajima dok je druga polovica subjekata stimulirana sa auditornim i vizualnim stimulacijama istovremeno, s time da je upotreba vizualnih stimulacija opadala s brojem sesija tako da su u posljednjoj sesiji svi subjekti koristili samo auditorne podražaje. Najbolje rezultate ostvarila je druga grupa u sesijama kada su subjekti stimulirani s oba tipa podražaja, s postignutom grupnom točnosti između 60% i 90% i prosječnom brzinom prijenosa podataka između 2 bita/min i 4 bita/min. Ista grupa stimulirana samo auditornim podražajima (nakon 3 sesije) ostvarila je točnost između 20% i 30%, međutim grupna točnost je rasla s brojem sesija, tako da je u posljednjoj sesiji ostvarena prosječna točnost od oko 70%. Kod prve grupe subjekata također je primijećeno poboljšanje točnosti s dužim korištenjem sustava (barem kod prve četiri sesije), međutim u većini sesija ostvarena točnost na svim subjektima varira između 50% i 70%, dok prosječni *ITR* varira između 0.5 bita/min i 2.5 bita/min. Promatrajući samo posljednju sesiju u kojoj je korišten samo auditorni BCI sustav, druga grupa subjekata ostvarila je nešto bolje rezultate te je prosječna točnost grupe 69% naspram 60% kolika je ostvarila prva grupa subjekata. Osim velike varijacije točnosti i *ITR*-a između različitih sesija, uočene su velike varijacije među subjektima unutar iste sesije.

Potreba za povećanjem *ITR*-a dovela je do upotrebe dvodimenzionalnih stimulacija [70] u kojima je korisniku predstavljena 3x3 matrica, gdje svaka ćelija odgovara broju 1-9, dok ćelije s brojevima 2-9 imaju dodatna 3-4 slova engleske abecede u konfiguraciji sličnoj telefonskoj tipkovnici. Auditorna stimulacija definirana je visinom tona i smjerom podražaja (lijeva/desna slušalica). Naime prvi i treći stupac matrice određeni su stimulacijama na lijevoj odnosno desnoj slušalici dok istovremeno korištenje i lijeve i desne slušalice označava središnji stupac. Redci matrice definirani su s tri distinktivna tona vrlo različitih frekvencija, čime sustav s moduliranjem visine i smjera dolaska stimulacije istovremeno određuje traženi redak i stupac. Selekcija ćelije matrice vrši se kroz petnaest sekvenci u kojima se subjekt stimuliran sa svih devet kombinacija visine i smjera dolaska tona. Nakon što korisnik odredi niz ćelija matrice unutar kojih se nalaze slova željene riječi, odabirom tipke „1“ i ulaskom u sljedeću fazu u istoj 3x3 matrici prikazane su najčešće korištene njemačke riječi koje se mogu napisati navedenom kombinacijom ćelija. Ponavljanjem dodatnih 15 sekvenci korisnik odabire željenu riječ. Mogućnost korekcije omogućila je veliku točnost sustava, pogotovo jer su subjekti bili obavezni korigirati svoj izbor u slučaju pogrešnog odabira. Deset subjekata dobilo je zadatak napisati dvije rečenice, od kojih se prva sastoji od 18, a druga od 36 slova/znakova. Sedam subjekata uspjelo je napisati obje rečenice, dok je troje subjekata napisalo jednu rečenicu, te je u prosjeku ostvaren *ITR* od 3 bita/min, dok je među subjektima *ITR* varirao između 2 i 5

bita/min.

Primjena prostorno orijentiranih auditornih stimulacija istražena je u [71]. U navedenom radu sustav se sastoji od pet do osam zvučnika ravnomjerno raspoređenih oko subjekta, gdje je kao optimalna konfiguracija odabrana konfiguracija sa šest zvučnika [72]. Svaki zvučnik predstavlja jednu klasu podataka unutar koje se nalazi pet abecednim redom poredanih slova i opcionalno dodatni znakovi, tako da ton iz prvog zvučnika predstavlja slova od A do E, drugi od F do J, dok posljednji Z i ostatak znakova koje sustav sadrži. Unutar svake klase nalazi se i opcija za povratak, a odabir slova odvija se u dvije faze. U prvoj fazi, kroz 15 sekvenci sustav u nasumičnom redoslijedu generira podražaje sa svih šest zvučnika, na temelju čega se odabire željena grupa slova/znakova. U drugoj fazi, istim postupkom odabire se jedno od pet slova iz odabrane grupe, s time da posljednji smjer stimulacije (šesti zvučnik) predstavlja mogućnost povratka na početnu fazu. Od 21 subjekta koliko je sudjelovalo u prvoj sesiji, 16 subjekata je bilo uspješno i pozvano na sljedeću sesiju u kojoj su subjekti dobili zadatak napisati dvije njemačke rečenice. Samo jedan subjekt je ostvario jako loše rezultate u prvoj rečenici zbog čega je odustao od pisanja druge. Ostatak subjekata ostvario je vrlo dobre rezultate sa točnostima između 70% i 100%, te *ITR*-om između 2 i 8 bita/min, odnosno nakon dvije rečenice prosječna ostvarena vrijednost točnosti i *ITR*-a iznosi 85.2% odnosno 5.11 bita/min.

Iako su kod svih navedenih auditornih BCI sustava dobivene jako dobre točnosti i prilično dobre *ITR* vrijednosti, navedeni sustavi imaju veliki nedostatak, koji će sigurno utjecati na točnost u konačnoj implementaciji, a moguće i samu primjenu predloženih sustava kod krajnjih korisnika. Naime svaki od prethodno opisanih BCI sustava koristi vizualnu pomoć kojom je osigurana veća točnost i brži prijenos podataka. Vizualna konfiguracija navedenih BCI sustava prebacila je kompleksnost operacije kao što je pisanje s auditornih stimulacija na kognitivnu sposobnost subjekta da iz definirane vizualne mape slova, brojeva i/ili znakova odredi tip ili dolazeći smjer ciljane stimulacije. Primjenom kratkih i jednostavnih stimulacija moguće je smanjiti interval između dvije uzastopne stimulacije te tako direktno osigurati veći *ITR*, ali i povećati točnost sustava kroz veći broj ERP signala koje je u istom vremenskom intervalu moguće prikupiti. Korištenje kratkih jednostavnih stimulacija i vizualne podrške ima pozitivan utjecaj na P300 signal, generirajući neurološke reakcije većeg intenziteta koje je jednostavnije klasificirati. Međutim ovakvi sustavi ograničeni su na subjekte s ranijim stadijem ALS-a u kojem subjekt potencijalno još ima sposobnost kontrole očiju gdje bi se privikavanjem subjekta na BCI sustav u ranijim fazama bolesti vjerojatno omogućilo kasnije uspješno korištenje sustava i bez vizualne podrške. Osobe koje imaju probleme s očima ili su već u kasnijem stadiju ALS-a nije moguće istrenirati na predložene sustave, uz dodatni problem da bi povezivanje

auditorne stimulacije i njenog značenja u procesu pisanja vjerojatno ipak bio pretežak kognitivan zadatak.

Izostavljanje vizualne podrške ostvareno je u novoj BCI paradigmi [73] u kojoj su grupe slova definirane pomoću šest različitih njemačkih riječi, koje zajednički sadrže sva slova njemačke abecede bez ponavljanja. U prvoj fazi u trajanju od 10 sekvenci u kojoj se svaka riječ subjektu prezentira jedanput, subjekt se fokusira na riječ koja sadrži ciljano slovo. Ovisno o riječi/stimulaciji, vremenski interval između dvije stimulacije iznosi između 600 ms i 1400 ms. U drugoj fazi, svako slovo iz prethodno odabrane riječi zasebno se prezentira subjektu. Jedanaest zdravih subjekata ostvarilo je izvrsnu prosječnu točnost od 86% u pisanju tri kratke riječi gdje su samo tri subjekta ostvarili točnost manju od 70%, međutim uz jako mali *ITR* koji u prosjeku iznosi 1.11 bita/min. Dodatna mjerenja na četiri subjekta bez motoričkih sposobnosti pokazala su također izvrsnu prosječnu točnost od 84%, te prosječnu *ITR* vrijednost od 1.3 bita/min, pokazavši da predloženo sučelje mozak – računalo svakako predstavlja koncept koji bi se mogao primijeniti kod krajnjih korisnika.

Höhne i Tangermann u svom radu [74] predlažu primjenu niza slova kao stimulacija u BCI sustavu za pisanje. Predložene su dvije eksperimentalne paradigme, gdje se prva sastoji od niza nasumično raspoređenih slova engleske abecede, dok je u drugoj predložena uporaba niza slova koji su abecednom redu prezentirani subjektu. Iako prva konfiguracija teoretski osigurava snažniji i izraženiji P300 odziv koji je moguće lakše klasificirati, autori studije odlučili su se na primjenu posljednje konfiguracije s argumentom da je više prilagođena sposobnostima krajnjih korisnika auditornih sustava. Odabir konfiguracije utjecao je na točnost sustava gdje je deset subjekata kroz tri rečenice ostvarilo prosječnu točnost od 34%, uz maksimalnu točnost pri pisanju jedne rečenice od 75%. Povrh toga loša točnost sustava imala je utjecaj i na ostvareni *ITR* koji u prosjeku iznosi 1.3 bita/min. Iako su ostvareni rezultati u gotovo svim mjerenjima daleko ispod razine potrebne za normalnu komunikaciju, istovjetnost stimulacije i slova kao sastavnih dijelova svake riječi odnosno rečenice čini predloženu paradigmu veoma privlačnu kao osnovu za auditorne BCI sustave namijenjene CLIS osobama.

Diskutirani auditorni BCI sustavi pokazali su svoje nedostatke u usporedbi sa sustavima koji koriste vizualne stimulacije, prvenstveno zbog izraženijih P300 neuroloških reakcija koje izazivaju vizualne stimulacije. Osim navedenoga, mogućnosti brže stimulacije odnosno prikupljanja više ERP signala u svrhu povećanja SNR-a osigurava veću točnost, a samim time i veći *ITR*. Također većina sustava koristi vizualnu podršku barem tijekom privikavanja subjekta na korišteno sučelje, što kod krajnjih korisnika može predstavljati nepremostiv problem. S ciljem smanjenja utjecaja navedenih nedostataka auditornih sučelja, u ovom radu

predloženo je auditorno sučelje mozak-računalo čija je konfiguracija i odabir stimulacija maksimalno pojednostavljena i prilagođena krajnjim korisnicima. Primjena naprednih metoda obrade signala i klasifikacije osigurala je zadovoljavajuću točnost, čime su ostvarene kompetitivne *ITR* vrijednosti koje su usporedive, a u nekim slučajevima bolje od vrijednosti ostvarenih u prezentiranim istraživanjima.

3. Sučelje mozak-računalo za pisanje – eksperimentalna paradigma

3.1. Eksperimentalna paradigma

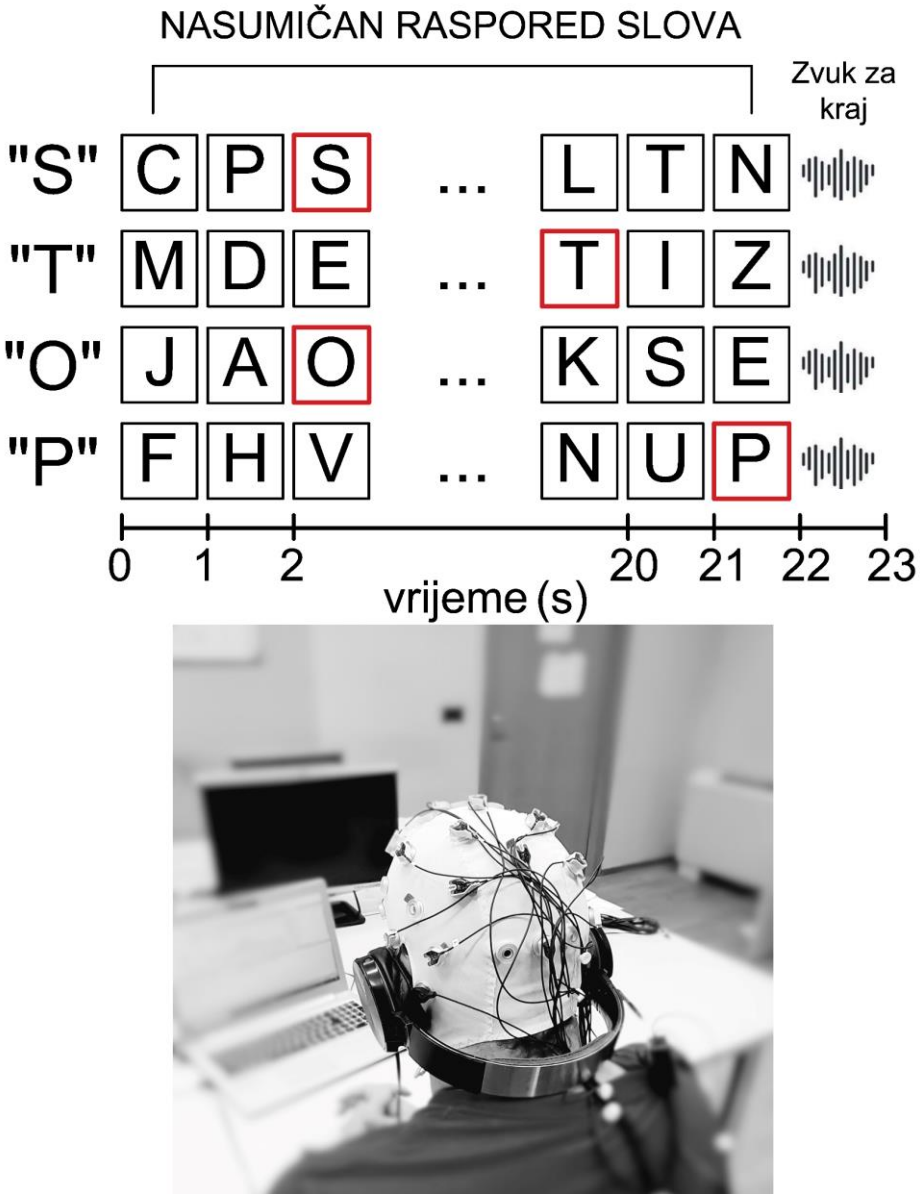
S obzirom na izvrsne mogućnosti vizualnih BCI sustava za pisanje, primjena auditornih podražaja ima smisla samo kod osoba s djelomično ili potpuno nefunkcionalnim organom vida, gdje su nerijetko takve osobe u CLIS stanju. Navedena ograničenja čine većinu prethodno opisanih auditornih sučelja koji koriste vizualnu asistenciju u svrhu olakšanja primjene sustava i povećanja točnosti nepogodnima za krajnje korisnike sustava. Povrh toga većina sustava zahtijeva kognitivno povezivanje auditorne stimulacije s pripadajućim slovom, dodatno ograničavajući primjenu BCI sustava kod ciljane grupe osoba.

Kako bi predloženo sučelje mozak-računalo za pisanje uopće bilo primjenjivo kod navedene grupe ljudi, potrebno je odabrati stimulacije s kojima je osoba već upoznata s ciljem izbjegavanja učenja i prilagodbe na podražaje, a čija će značenja omogućiti korisniku smislenu komunikaciju. Uzimajući navedeno ograničenje u obzir, sučelje je moguće ostvariti preko dvije vrste stimulacija, gdje prvu vrstu podražaja predstavljaju riječi. Upotreba riječi omogućit će veoma ograničenu komunikaciju, gdje je broj riječi kojima se subjekt može stimulirat ograničen na kontekst postavljenog pitanja, čineći samoinicijativnu komunikaciju gotovo nemogućom. Drugi odabir stimulacija predstavljaju sastavni elementi svake riječi odnosno slova, čija fleksibilnost naravno potiče svestraniju komunikaciju. Gledajući sa stajališta fleksibilnosti sustava slova predstavljaju puno bolji izbor, međutim navedena fleksibilnost posljedično će uzrokovati manji *ITR*, što kompletan sustav može učiniti nepraktičnim za normalnu uporabu. Očito je da oba koncepta imaju svoje prednosti i mane, međutim uporaba slova/fonema kao podražaja za predloženo sučelje mozak-računalo djeluje kao ipak bolji odabir. Unatoč tome korištenje riječi ili čak kratkih rečenica u BCI sustavu svakako bi mogla biti posljednja mogućnost za uspostavljanje i najmanje moguće komunikacije s CLIS osobama [65].

Kao optimalno rješenje za predloženo sučelje odabran je niz stimulacija od 22 slova hrvatske abecede, isključena su slova s dijakritičkim znakovima (č, ć, đ, š, ž) i složena slova (dž, lj, nj), čime je još uvijek moguće ostvariti pisanu komunikaciju razumljivu svima. Takvom redukcijom slova povećan je *ITR*, imajući na umu da povećanje *ITR*-a neće biti moguće smanjivanjem intervala između stimulacija kao u dosad predloženim paradigmama. Povrh toga navedena redukcija ne bi trebala imati utjecaj na točnost sustava jer je vjerojatnost pojavljivanja

ciljane stimulacije (p = 0.047) još uvijek dovoljno mala za generiranje izraženije P300 neurološke reakcije. Na slici 3.1. prikazana je predložena eksperimentalna paradigma.

Eksperimentalna paradigma definirana je na način da se sastoji od N segmenta, gdje je N ukupan broj slova riječi ili rečenica koje korisnik želi napisati. Za prikazanu situaciju na slici

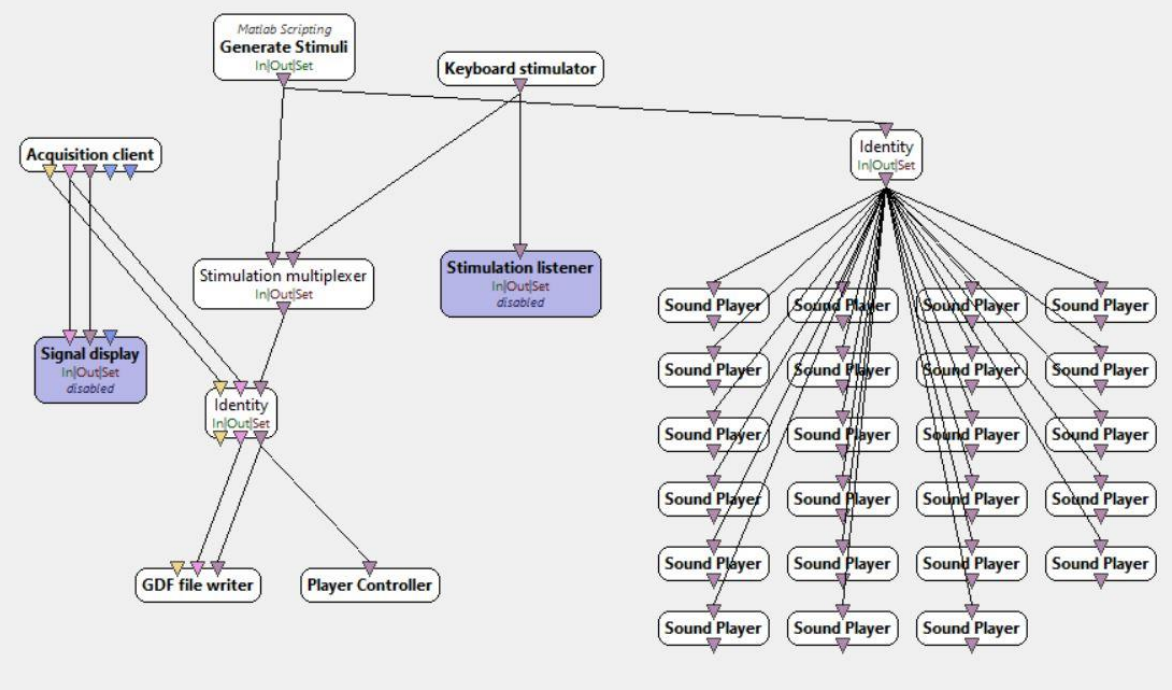


Slika 3.1. Prikaz predložene eksperimentalne paradigme kao osnove za auditorno sučelje mozak-računalo. Svako traženo slovo određeno je nizom od 22 odabrana slova hrvatske abecede koja se nasumično prezentiraju korisniku s razmakom od jedne sekunde, a čiji se ERP mjeri EEG uređajem. Crvenim okvirom u svakom segmentu označena su ciljana slova, dok visokofrekventni zvuk označava kraj trenutnog odnosno početak slijedećeg segmenta. Ispod vremenske osi nalazi se fotografija subjekta u laboratoriju tijekom provedbe eksperimenta.

3.1. korisnikov zadatak je napisati riječ „STOP“, zbog čega se mjerenje sastoji od ukupno četiri segmenta. Unutar jednog segmenta niz od 22 prethodno definirana slova hrvatske abecede prezentiraju se korisniku u nasumičnom redoslijedu uz pomoć slušalica koje osim zvučnih podražaja osiguravaju dodatnu akustičnu izolaciju od vanjskih smetnji [75]. Svaki segment razdvojen je visokofrekventnim zvučnim signalom, koji ujedno služi kao signal korisniku za prebacivanje fokusa na sljedeće ciljano slovo pisane riječi/rečenice. Razmak između dvije uzastopne stimulacije podesiva je veličina, a kao odgovarajuća vrijednost uzeta je jedna sekunda što je za sve ispitanike bio vremenski interval koji je omogućio opušteno praćenje stimulacija.

Dodatno pojednostavljenje i adaptacija sustava na potrebe potencijalnih korisnika predloženog BCI sustava svakako bi predstavljala organizacija stimulacija unutar segmenta u abecednom redoslijedu [74]. Na taj način, zbog poznavanja redoslijeda slova abecede, korisniku bi se dodatno omogućile relativno dugačke faze „mirovanja“, u kojima se ne bi morao fokusirati na svako slovo niza. Međutim izostavljanjem nasumičnosti iz predloženog niza stimulacija kao što je naznačeno već u prethodnom poglavlju utjecat će na same neurološke reakcije u mozgu, odnosno do ograničavanja amplitude ili čak izostanka P300 reakcije čime će klasifikacija ciljanih i ne-ciljanih stimulacija biti značajno otežana. Otežana klasifikacija predstavljat će nadalje veliki problem za sučelje upravo iz razloga što predložena paradigma koristi ne-iterirajuću strukturu (engl. *single-trial*) u kojoj se svaka stimulacija neovisno o tome radi li se o ciljanom ili ne-ciljanom podražaju ponavlja samo jedanput, zbog čega će svaka loša reakcija na traženo slovo gotovo sigurno nepovoljno utjecati na odabir istog.

U dosadašnjim ispitivanjima BCI sustava na zdravim ispitanicima neovisno o tome radi li se o sustavima s vizualnim ili auditornim podražajima, od korisnika se zahtijevalo da drže otvorene oči uz čim manje pokreta (ograničeno otvaranje i zatvaranja kapaka, fokus na jednu točku u slučaju auditornih sustava i sl.). Razlog tome su pojačane moždane aktivnosti u alfa frekvencijskom području (8-12 Hz) u okcipitalnoj regiji mozga prilikom zatvorenih očiju, a čija amplituda u potpunosti može prekriti P300 odziv na ciljanu stimulaciju. Osim navedenoga nedostaci otvorenih očiju mogu se manifestirati u obliku naglih porasta amplituda u mjerenom signalu zbog čega je potrebna dodatna obrada signala kako bi se uklonile neželjene aktivnosti u signalu. Kako za predloženu eksperimentalnu paradigmu nisu potrebne vizualne stimulacije ili vizualne povratne informacije, sva buduća ispitivanja odrađena su tako da su korisnici prilikom aktivne faze eksperimenta imali zatvorene oči. Na taj način kako će pokazati kasnija analiza mjerenja, smanjila se potreba za obradom i uklanjanjem artefakata nastalih pomicanjem



Slika 3.2. Prikaz implementacije predložene eksperimentalne paradigme u *OpenVibe* razvojnom okuženju.

mišića očiju ili kapaka, a sama paradigma je dodatno prilagođena krajnjim korisnicima predloženog sustava čije su oči najčešće konstantno zatvorene. Uz navedeno pretpostavka je da će zatvorene oči kod korisnika imati pozitivan utjecaj na fokus osobe, a dodatna motivacija svakako je istraživanje [76] u kojem se sugerira primjena zatvorenih očiju kod BCI sustava s auditornim podražajima.

3.2. Implementacija eksperimentalne paradigme

Eksperimentalna paradigma izvedena je u *OpenVibe* [77] razvojnom okruženju koje je kompletno namijenjeno projektiranju, testiranju i implementaciji BCI sustava te obradi neuroloških aktivnosti u stvarnom vremenu. Grafičkim programiranjem odnosno povezivanjem pojedinih funkcijskih blokova linijama koje predstavljaju signale omogućuje se prilično jednostavno projektiranje i konfiguriranje željenog sučelja. Također, *OpenVibe* omogućuje pozivanje funkcija iz drugih često korištenih programskih jezika i okruženja kao što su C++, Python, MATLAB, čime je pojedinu funkciju sučelja moguće implementirati u okruženju koje je za to najpogodnije. Implementacija eksperimentalne paradigme prikazana je na slici 3.2. i podijeljena je u funkcionalne cjeline opisane u nastavku poglavlja.

3.2.1. Acquisition Client

Acquisition client modul je dio sustava čiji je zadatak povezivanje s uređajem za mjerenje neuroloških aktivnosti te prihvat izmjerene aktivnosti. Blok omogućuje povezivanje s različitim tipovima uređaja različitih proizvođača mjerne opreme, a u ovom istraživanju blok je implementiran za povezivanje s korištenim EEG mjernim uređajem. Blok sadrži nekoliko izlaznih veličina kao što je mjereni neurološki signal, informacije o eksperimentu i mjernom uređaju koji se koristi, te stimulacijski markeri ili markeri o povratnoj informaciji korisnika generiranih upotrebom različitih uređaja (npr. tipkala, …) priključenih direktno na mjerni uređaj.

3.2.2. Generate Stimuli

Generate Stimuli blok dio je sustava koji se koristi za generiranje zvučnih podražaja odnosno za generiranje niza od 22 nasumično poredana slova hrvatske abecede. Unutar bloka definirane su tri MATLAB .m funkcije koje koordiniraju sustav i generiraju nasumične nizove stimulacija, a koje će se pozivati prilikom pokretanja sustava. Prva funkcija *Initialize* koristi se za inicijalizaciju potrebnih globalnih varijabli, te se navedena funkcija poziva samo jedanput prilikom pokretanja eksperimenta. Pozivanjem navedene funkcije iz baze podataka riječi hrvatskog jezika, odabire se nasumično riječ koju će korisnik pokušati napisati koristeći samo svoje mentalne reakcije prilikom opažanja ciljanog slova. Odabrana riječ vizualno će biti prikazana korisniku nakon čega slijedi pauza od 5 sekundi koja omogućuje dodatnu kratku pripremu prije nego što sustav počne generirati stimulacije u obliku zvučnih podražaja. Odabirom tražene riječi sustav automatski generira matricu koja ima isti broj redaka kao broj slova pisane riječi, a u svakom retku nalaze se 22 nasumično poredane stimulacije.

Glavni dio bloka odnosi se na funkciju *Process* koja se kontinuirano poziva s frekvencijom podesivom unutar bloka, a koja može poprimiti bilo koju cijelu vrijednost na intervalu od 1 do 128 Hz. Za potrebe ove paradigme odabrana je frekvencija od 16 Hz. Ovisno o definiranom intervalu između dvije stimulacije, funkcija u točno određenim vremenskim intervalima na svom izlazu generira specifične numeričke vrijednosti koji predstavljaju stimulaciju u obliku slova. Osim navedenih stimulacija određene identifikacijske numeričke vrijednosti pridijeljene su i različitim događajima unutar eksperimenta koji olakšavaju analizu mjerenja, kao što su markeri za početak i kraj mjerenja ili početak i kraj segmenta. Generirane numeričke vrijednosti stimulacija mogu se koristiti kao ulazi u ostale blokove prikazane arhitekture eksperimentalne

Tablica 3.1. Popis svih stimulacija i markera korištenih u predloženoj eksperimentalnoj paradigmi zajedno s pridruženim *OpenVibe* nazivima i jedinstvenom identifikacijskom numeričkim vrijednostima.

Slovo/stimulacija/marker	Naziv OpenVibe stimulacije	Identifikacijska numerička vrijednost OpenVibe stimulacije
A	OVTK_StimulationId_Label_01	33025
B	OVTK_StimulationId_Label_02	33026
C	OVTK_StimulationId_Label_03	33027
D	OVTK_StimulationId_Label_04	33028
E	OVTK_StimulationId_Label_05	33029
F	OVTK_StimulationId_Label_06	33030
G	OVTK_StimulationId_Label_07	33031
H	OVTK_StimulationId_Label_08	33032
I	OVTK_StimulationId_Label_09	33033
J	OVTK_StimulationId_Label_0A	33034
K	OVTK_StimulationId_Label_0B	33035
L	OVTK_StimulationId_Label_0C	33036
M	OVTK_StimulationId_Label_0D	33037
N	OVTK_StimulationId_Label_0E	33038
O	OVTK_StimulationId_Label_0F	33039
P	OVTK_StimulationId_Label_10	33040
R	OVTK_StimulationId_Label_11	33041
S	OVTK_StimulationId_Label_12	33042
T	OVTK_StimulationId_Label_13	33043
U	OVTK_StimulationId_Label_14	33044
V	OVTK_StimulationId_Label_15	33045
Z	OVTK_StimulationId_Label_16	33046
POVRATAK	OVTK_StimulationId_Label_17	33047
visokofrekventni signal	OVTK_StimulationId_Beep	33282
pritisak tipkala	OVTK_StimulationId_Button1_Pressed	32786
otpuštanje tipkala	OVTK_StimulationId_Button1_Released	32787
početak eksperimenta	OVTK_StimulationId_ExperimentStart	32769
kraj eksperimenta	OVTK_StimulationId_ExperimentStop	32770
početak segmenta	OVTK_StimulationId_SegmentStart	32771
kraj segmenta	OVTK_StimulationId_SegmentStop	32772
kraj datoteke	OVTK_StimulationId_EndOfFile	33284

paradigme objašnjene u nastavku poglavlja, a koji će ovisno o aktivnoj stimulacijskoj vrijednosti definirati svoju reakciju. Popis svih slova i markera koji se koriste u paradigmi odnosno predloženom sučelju kao i pripadajuće numeričke vrijednosti prikazane su u tablici 3.1. Identično inicijalizaciji sustava, prilikom završetka izvođenja eksperimentalne paradigme odnosno mjerenja sustav jednokratno poziva .m funkciju *Uninitialize* za de-inicijalizaciju korištenih globalnih varijabli.

3.2.3. Keyboard stimulator

Prilikom testiranja novih paradigmi, često se od korisnika zahtjeva povratna informacija o registriranoj ciljanoj stimulaciji. Najčešće je povratna informacija definirana kao tipkalo koje korisnik mora pritisnuti prilikom detektiranja ciljane stimulacije. Za potrebe ove paradigme koristeći navedeni blok, tipke *Space* i *Enter* na tipkovnici računala definirane su kao tipke koje korisnik može upotrijebiti za slanje povratne informacije o svojoj reakciji. Pritiskom i otpuštanjem tipke generiraju se na izlazu bloka markeri sa vrijednostima 33086 i 33087 kako je vidljivo iz tablice 3.1, a čija vremenska lokacija unutar spremljenih mjerenja ukazuje da li je i u kojem trenutku došlo do reakcije korisnika.

3.2.4. Sound Player

Svi zvučni podražaji koji se koriste u ovoj paradigmi zasebno su snimljeni te su pohranjeni u obliku *.wav* formata. Svaki od prikazanih *Sound Player* blokova sadrže informaciju o zvučnoj stimulaciji, te odgovarajuću numeričku vrijednost stimulacije koja će aktivirati zvučni podražaj. Drugim riječima, kada blok *Generate Stimuli* odredi slovo „A“ kao sljedeći aktivni podražaj definiran identifikacijskim brojem 33025, tada će odgovarajući *Sound Player* blok koji u sebi sadrži navedeni identifikacijski kod i *.wav* datoteku generirati željeni zvučni podražaj.

Sva mjerenja neurološke aktivnosti prilikom izvođenja eksperimentalne paradigme kao i pripadajući markeri pohranjuju se u datoteku GDF formata pomoću bloka *GDF File Writer*. Tako pohranjene datoteke je kasnije moguće otvoriti u MATLAB programskom okruženju radi daljnje analize.

3.3. Metode klasifikacije mjerene neurološke reakcije

Prema definiranoj eksperimentalnoj paradigmi svaka stimulacija izazvat će dva tipa neuroloških reakcija ovisno o značenju stimulacije. Kako bi odredili tip stimulacije, izmjereni EEG signal nakon akustičnog podražaja potrebno je klasificirati primjenom binarnog klasifikatora. Za potrebe ovog rada klasifikacija između ciljanih i ne-ciljanih stimulacija izvršena je uz pomoć dva modela strojnog učenja (engl. *Machine Learning*, ML). Prvi se odnosi na već dobro poznatu klasifikacijsku metodu, metodu potpornih vektora (engl. *Support Vector Machine*, SVM) koja na temelju izmjerenih EEG signala određuje potporne vektore *N*-dimenzionalne ravnine odnosno granice koja odvaja ERP signale ciljanih i ne-ciljanih stimulacija. Česta praksa pri korištenju SVM-a je redukcija dimenzionalnosti podataka kako bi se pojednostavio model i skratilo vrijeme učenja klasifikatora. U tu svrhu izmjereni podatci su filtrirani pomoću *xDAWN* prostornog filtera čiji je zadatak isticanje ERP signala povezanih s P300 odzivom odnosno neurološkom reakcijom na ciljano slovo. Druga metoda klasifikacije je konvolucijska neuronska mreža (engl. *Convolutional Neural Network*, CNN) čiji su izvrsni rezultati kod obrade slika odnosno detektiranja objekata unutar slike potaknuli također uporabu navedene klasifikacijske metode u ostalim područjima. Obje klasifikacijske metode kao i *xDAWN* prostorni filter prezentirani su u nastavku.

3.3.1. xDAWN prostorni filter

Loš omjer korisnog P300 signala i ostale izmjerene neurološke aktivnosti koja nije evocirana detektiranim podražajem, glavni je razlog pogrešne klasifikacije EEG signala na ERP izazvane ciljanom ili ne-ciljanom stimulacijom što je do sada često kompenzirano kroz usrednjavanje višestrukih EEG mjerenja izazvanih istovjetnom stimulacijom. Ideja *xDAWN* algoritma je definiranje prostornog filtera čiji je zadatak projiciranje *N*-dimenzionalnog EEG mjerenja u novi *N*-dimenzionalni prostor u kojem je P300 odziv maksimiziran [78], [79]. Za razliku od PCA kod koje je novi prostor projiciranja EEG mjerenja $\boldsymbol{X}$ definiran međusobno ortogonalnim jedinstvenim vektorima dobivenim dekompozicijom singularnih vrijednosti (engl. *Singular Value Decomposition*, SVD) matrice kovarijance $\boldsymbol{XX^T}$ [80], *xDAWN* algoritam izmjerenu neurološku aktivnost $\boldsymbol{X} \in R^{N_t \, x \, N_s}$, gdje N_t predstavlja broj vremenskih uzoraka, a N_s broj korištenih elektroda, prvo rastavlja u dvije komponente kako je prikazano u sljedećem izrazu:

$$\boldsymbol{X = DA + N}, \tag{3.1}$$

gdje je $\boldsymbol{DA}$ izmjerena neurološka aktivnost povezanu sa ciljanim stimulacijama, dok je $\boldsymbol{N}$ sva preostala moždana aktivnost u što je uključenana pozadinska neurološka aktivnost, izmjereni potencijali na ne-ciljane stimulacije kao i mogući artefakti koji su nastali tijekom mjerenja. Matrica $\boldsymbol{A} \in R^{N_e \, x \, N_s}$ sadrži samo one dijelove EEG mjerenja koji su karakteristični za P300 odziv na ciljanu stimulaciju, dok matrica $\boldsymbol{D} \in R^{N_t \, x \, N_e}$ predstavlja Toeplitz matricu gdje je prvi stupac matrice definiran tako da ima vrijednost 1 u redcima odnosno vremenskim uzrocima u kojima je došlo do početka stimuliranja subjekta ciljanim podražajem, dok su ostale vrijednosti postavljene na nulu. N_e predstavlja broj uzoraka EEG mjerenja nakon stimulacije koji sadrži neurološku reakciju na ciljanu stimulaciju odnosno duljinu epohe, gdje je česta praksa da se promatra vremenski interval EEG signala između 600 ms i 1000 ms ovisno o tipu korištene stimulacije. Rješenje estimacije P300 odziva $\boldsymbol{A}$ pomoću metode najmanje kvadratne udaljenosti (engl. *Least Square Estimation*, LSE) uz minimizacijsku funkciju $\widehat{\boldsymbol{A}} = \arg\min_{A} \|\boldsymbol{X} - \boldsymbol{DA}\|_2^2$ određeno je sljedećim izrazom:

$$\widehat{\boldsymbol{A}} = (\boldsymbol{D}\boldsymbol{D}^{\boldsymbol{T}})^{-1}\boldsymbol{D}^{\boldsymbol{T}}\boldsymbol{X}. \tag{3.2}$$

Prostorni filter $\boldsymbol{U} \in R^{Ns \, x \, Nf}$ definiran je tako da množenjem s mjerenim EEG signalom daje komponente povezane sa P300 neurološkim reakcijom $\widehat{\boldsymbol{S}}$, gdje je dimenzija filtera $1 \ll N_f \ll N_s$. Iz navedenog, (3.1) možemo proširiti množenjem cijelog izraza sa filterom $\boldsymbol{U}$:

$$\widehat{\boldsymbol{S}} = \boldsymbol{XU} = \boldsymbol{DAU} + \boldsymbol{NU}. \tag{3.3}$$

Filter $\boldsymbol{U}$ definiran je tako da maksimizira koristan P300 signal definiran izrazom $\boldsymbol{DAU}$ naspram cjelokupnog projiciranog EEG signala $\boldsymbol{XU}$, odnosno da je zadovoljena sljedeća maksimizacijska funkcija:

$$\widehat{\boldsymbol{U}} = \underset{\widehat{U}}{\operatorname{argmax}} \frac{Tr\left(\boldsymbol{U}^{\boldsymbol{T}}\widehat{\boldsymbol{A}}^{\boldsymbol{T}}\boldsymbol{D}^{\boldsymbol{T}}\,\boldsymbol{D}\widehat{\boldsymbol{A}}\boldsymbol{U}\right)}{Tr(\boldsymbol{U}^{\boldsymbol{T}}\boldsymbol{X}^{\boldsymbol{T}}\boldsymbol{X}\boldsymbol{U})}, \tag{3.4}$$

gdje je Tr matematički operator koji zbraja elemente glavne dijagonale matrice.

Rješenje (3.4) moguće je odrediti supstitucijom matrice estimacije $\widehat{\boldsymbol{A}}$ s (3.2) i QR faktorizacijom matrica $\boldsymbol{X} = \boldsymbol{Q_x R_x}$ i $\boldsymbol{D} = \boldsymbol{Q_D R_D}$, gdje su matrice $\boldsymbol{Q_x}$ i $\boldsymbol{Q_D}$ ortogonalne, a $\boldsymbol{R_x}$ i $\boldsymbol{R_D}$ gornje trokutaste matrice. Prostorni filter određen je jedinstvenim vektorima primjenom SVD metode na matrici $\boldsymbol{Q_D}^{\boldsymbol{T}}\boldsymbol{Q_x} = \boldsymbol{\Phi\Lambda\Psi}^{\boldsymbol{T}}$, gdje $\boldsymbol{\Psi}$ i $\boldsymbol{\Lambda}$ označavaju matricu jedinstvenih vektora odnosno karakterističnih vrijednosti, tako da je konačno rješenje maksimizacijske

funkcije (3.4) definirano sljedećim izrazom:

$$\widehat{\boldsymbol{U}} = \boldsymbol{R_x}^{-1}\boldsymbol{\Psi}. \tag{3.5}$$

Svaki jedinstveni vektor određen je svojom karakterističnom vrijednošću koja definira energiju projicirane komponente. Primjenom karakterističnih vrijednosti moguće je odbaciti komponente (jedinstvene vektore) koje imaju relativnu malu energiju, čime je značajno moguće reducirati dimenziju filtera N_f. Prema [81] preporuka je da dimenzija filtera ne prelazi 25% ukupnog broja elektroda N_S.

3.3.2. Metoda potpornih vektora

SVM metoda jedna je od najpopularnijih metoda strojnog učenja koja je iznimno uspješna u binarnim klasifikacijskim problemima. SVM metodom određena ravnina najbolje razdvaja ulazne podatke u dvije klase 0/-1 (ne-ciljana) i 1 (ciljana) na temelju udaljenosti ravnine od najbližih točaka ulazne varijable. Navede točke najbliže ravnini definiraju potporne vektore koji podupiru odnosno određuju razdvajajuću ravninu [82].

Ovisno o rasporedu točak, tj. njihovoj klasi, moguće je koristiti različite linearne ili nelinearne *Kernel* funkcije kako bi se dobila ravnina koja zadovoljavajuće dobro razdvaja opisane točke. Korištenjem linearnih *Kernel* funkcija dobivamo linearnu SVM ravninu koja nije uvijek u mogućnosti razdvojiti vrijednosti različitih klasa na željen način. Moguće rješenje predstavlja upotreba nelinearnih *Kernel* funkcija u kreiranju nelinearne ravnine, koja će optimalnije razdvajati dvije klase podataka. Unatoč velikoj prednosti pred linearnim *Kernel* funkcijama, primjena nelinearnih funkcija može uzrokovati pretreniranost SVM modela, zbog čega je linearna *Kernel* funkcije svakako bolja početna opcija.

Primjena SVM metode s nelinearnom *Kernel* funkcijom na nereduciranim EEG podatcima rezultirala bi veoma kompleksnom ravninom s velikim brojem parametara, što bi sam klasifikacijski model i njegovo učenje činilo veoma nepraktičnim. Iz navedenog razloga, *xDAWN* prostorni filter primijenjen je na EEG podatcima, kako bi se istaknule komponente neurološke aktivnosti povezane sa P300 odzivom čije će karakteristike biti djelotvornije razdvojene ravninom.

3.3.3. Konvolucijska neuronska mreža

Veliki uspjeh konvolucijskih neuronskih mreža u klasifikaciji fotografija odnosno objekata na digitalnim fotografijama [83], potaknulo je primjenu CNN-a i u ostalim poljima, pa tako i u klasifikaciji multidimenzionalnih vremenskih zapisa [84]. Cecotti i Gräser [85] primijenili su nekoliko različitih modela CNN-a na podatcima dobivenih korištenjem vizualnog P300 Matrix Spellera, te je u najboljoj konfiguraciji ostvarena prosječna točnost od 95.5%. Povrh toga primjena CNN-a predložena je i u detekciji zamišljanja pokreta odnosno SMR-a, dajući slične rezultate kao i ostale dotad korištene klasifikacijske metode [86].

U ovom radu kao klasifikacijska metoda za kategorizaciju izmjerenih ERP signala na ciljane i ne-ciljane stimulacije odabrana je konvolucijska neuronska mreža EEGNet [87]. Predložena CNN projektirana je za klasifikaciju EEG signala u različitim BCI konfiguracijama, dok je mreža testirana na podatcima dobivenim korištenjem BCI sustava s ERP paradigmom (P300) ili SMR-om. Promatrajući samo rezultate ostvarene na P300 BCI paradigmi, predložen EEGNet model ostvario je identične rezultate kao i dotad predložena duboka konvolucijska mreža (deep ConvNet) [86], međutim značajna redukcija parametara mreže za treniranje (2258 kod najjednostavnije EEGNet 8,2 mreže naspram 114127 kod deep ConvNet) čini EEGNet mrežu puno pogodniju za korištenje u BCI sustavima. To je posebno značajno u P300 BCI sustavima gdje prikupljanje podataka za učenje klasifikatora može značajno potrajati zbog nepovoljnog omjera ciljanih i ne-ciljanih stimulacija.

EEGNet konvolucijska neuronska mreža sastoji se od dva konvolucijska sloja. U prvoj razini na ulazni EEG signal primjenjuje se F_1 temporalnih konvolucijskih filtera dimenzije $1 \times 0.5\,N_e$, gdje N_e predstavlja ukupan broj uzoraka epohe. Izlaz konvolucijskih filtera je matrica značajki EEG signala u F_1 različitih frekvencijskih područja. Nakon normalizacije podataka, svaki od izlaza povezan je sa novih D prostornih konvolucijskih filtera dimenzije $N_S \times 1$, gdje N_S kao i u slučaju *xDAWN* filtera predstavlja broj korištenih EEG elektroda. Navedenih $D \times F_1$ filtera pretražuju prostorne karakteristike u svakom od definiranih frekvencijskih područja, a dobiveni izlazni vektori dimenzije $1 \times N_e$ normalizirati će se prije primjene eksponencijalne linearne jedinice (engl. *Exponential Linear Unit*, ELU) kao aktivacijske funkcije. Prevencija pretreniranosti mreže u slučaju malog seta podataka za učenje riješena je pomoću Dropout tehnike [88] čija je vrijednost postavljena na 50%, a konačni rezultat dobiven je usrednjavanjem podataka čime je u svakom izlazu broj uzoraka smanjen četiri puta.

U slijedećem sloju svaki od izlaza prethodne razine odnosno svaka od dobivenih značajki

prvo je filtrirana s temporalnim konvolucijskim filterom dimenzije $1 \times 0.25\, N_e$. Kroz $F_2 = D \times F_1$ konvolucijih operacija međusobno se kombiniraju najbolje značajke dobivene različitim kombinacijama temporalnih i prostornih filtera, kako bi se osigurao odabir čim većeg broja karakteristika koje će uspješno razdvojiti dvije klase podataka. Nakon normalizacije podataka i primjene ELU aktivacijske funkcije, podatci su ponovo usrednjeni čime je veličina izlaznih podataka smanjena dodatnih 8 puta.

U predloženoj EEGNet arhitekturi dobivene značajke iz prethodnog sloja služe kao ulazni podatci u softmax klasifikator s *N* neurona, gdje svaki neuron predstavlja broj klasa podataka. Za potrebe ovog rada predložena neuronska mreža proširena je za dodatan sloj od 22 potpuno povezana neurona (broj različitih stimulacija/slova u predloženoj eksperimentalnoj paradigmi), koji je smješten između konvolucijskog i klasifikacijskog dijela CNN-a.

4. Rezultati analize eksperimentalnih mjerenja

U ovom poglavlju prikazani su rezultati analize neuroloških signala dobivenih primjenom predložene eksperimentalne paradigme koja će biti temelj sučelja mozak-računalo za pisanje. Zadatak subjekata je napisati slučajno odabranu riječ duljine od 3 do 6 slova, a prikupljena mjerenja obuhvatiti će dva tipa eksperimentalne paradigme: s povratnom informacijom u kojoj korisnik prilikom opažanja ciljanog slova mora pritisnuti za to predviđenu tipku na tipkovnici; i bez povratne informacije u kojoj korisnik samo kognitivno reagira na ciljanu stimulaciju.

Pošto je korištena ne-iterirajuća eksperimentalna paradigma odnosno ciljana stimulacija pojavljuje se samo jedanput unutar segmenta, za očekivati je da će analiza pripadajućih neuroloških reakcija na ciljane i ne-ciljanje podražaje pokazati vidljive razlike za navedena dva tipa stimulacija u svim ili gotovo svim segmentima. Očigledno je da će broj segmenata u kojima nije moguće uočiti jasnu razliku između ciljane i ne-ciljanih stimulacija, zbog čega će vrlo vjerojatno doći do pogrešne selekcije slova, odrediti točnost sustava i kasniju implementaciju predložene paradigme.

4.1. Provedba eksperimentalnih mjerenja

Uz predloženu eksperimentalnu paradigmu neizostavni dio BCI sustava, kako je već napomenuto, svakako je uređaj za mjerenje neurološke aktivnosti korisnika. Za potrebe ovog istraživanja korišten je akvizicijski uređaj V-Amp 16 proizvođača BrainProducts, čija je svrha pojačavanje i uzorkovanje neuro-električnih signala koji ne moraju nužno biti povezani s neurološkom aktivnosti mozga (EEG) već je uređajem moguće mjeriti i električne signale na drugim lokacijama na tijelu (mišići srca EKG, mišići očiju i očnih kapaka EOG, itd.). Uređaj podržava maksimalnu frekvenciju uzorkovanja od 2 kHz, dok je za potrebe mjerenja odabrana frekvencija uzorkovanja od 512 Hz koja je dovoljna za obuhvaćanje svih relevantnih neuroloških aktivnosti potrebnih za klasifikaciju opisanu u prethodnom poglavlju.

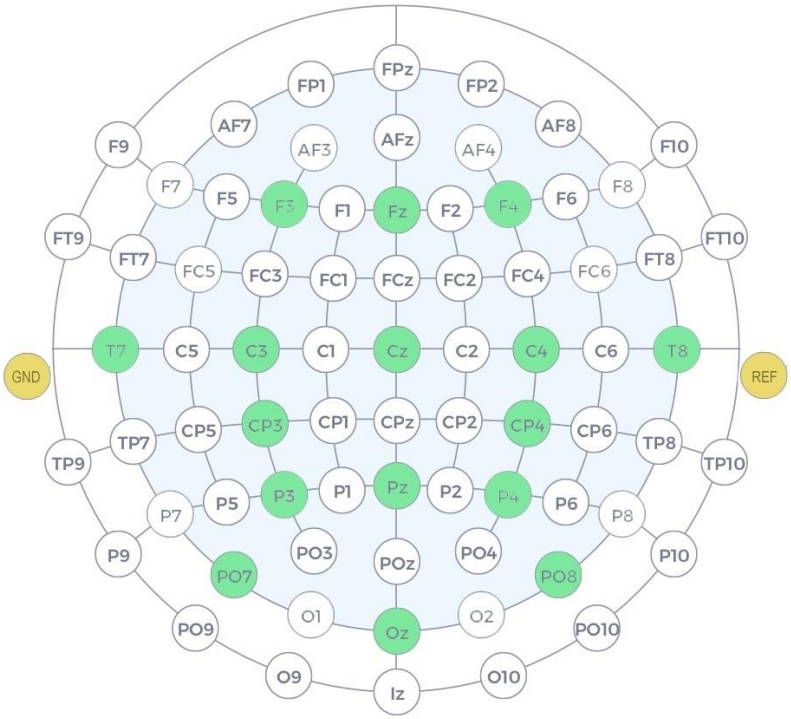
Navedeni uređaj može koristiti dva tipa elektroda: pasivne elektrode koje su po principu rada vrlo jednostavne, a radi se o elektrodama koje osim dobre električne provodljivosti ne posjeduju nikakva dodatna svojstva; te aktivne elektrode koje zbog dodatno ugrađene elektronike imaju svojstvo pojačanja signala i uklanjanja smetnji već na samom izvoru signala, čime je u većini



Slika 4.1. Prikaz Brain Products V-Amp akvizicijskog EEG uređaja korištenog u ovom doktorskom radu s 16 aktivnih elektroda pričvršćenih na prilagodljivu Acticap kapu.

slučajeva osigurana veća točnost mjerenog signala [89]. Naime, u električnim vodičima koji povezuju elektrode i akvizicijski uređaj, pod djelovanjem elektromagnetskih smetnji mogu se inducirati naponi čija magnituda može u potpunosti prekriti korisni mjereni signal. Pojačavanjem elektro-neurološkog signala na samom izvoru odnosno tjemenu korisnika, amplituda korisnog signala je iznad naponskih razina koje mogu uzrokovati vanjske smetnje zbog čega je osigurana velika robusnost mjerenog signala na okolno elektromagnetno zračenje.

U korištenoj konfiguraciji koja je prikazana na slici 4.1, sustav se sastoji od 16 aktivnih elektroda za mjerenje neurološke aktivnosti i dodatne dvije elektrode koje služe kao uzemljenje (GND) i referentni napon (REF), a koje se uz pomoć Acticap kape lagano i brzo montiraju na željene poziciji na tjemenu korisnika [90]. Samo postavljanje kape nije dovoljno jer se na velikom broju elektroda ne ostvaruje dobar kontakt s tjemenom korisnika zbog čega na navedenim elektrodama nije moguće mjeriti realnu neurološku aktivnost [91]. Samim time neophodno je primijeniti tanak sloj viskoznog gela adekvatne provodljivosti koji osigurava mali



Slika 4.2. Prikaz lokacija korištenih aktivnih mjernih elektroda (zelena boja) prema 10-20 normi uz dodatne dvije elektrode GND i REF (narančasta boja) postavljene na mastroidne kosti iza lijevog odnosno desnog uha subjekta. Prema konfiguraciji najzastupljenije su centralna i parijetalna regija u kojima se očekuje najjači P300 odziv.

kontaktni otpor između tjemena glave i elektroda [88]. Prilikom korištenja uređaja uz ispravno nanošenje gela sva mjerenja su odrađena sa kontaktnim otporom manjim od 5 k**Ω** na svim elektrodama.

Kako je cilj eksperimentalne paradigme odnosno sučelja mozak-računalo za pisanje detekcija P300 signala kao reakcije na ciljano slovo, pozicije elektroda na glavi prilagođene su navedenom zadatku. Tako se u konfiguraciji elektroda prikazanoj na slici 4.2 samo tri elektrode F3, Fz i F4 nalaze u frontalnoj regiji odnosno ocipitalnoj regiji PO7, Oz, PO8, dok je većina elektroda pozicionirana u centralnoj i parietalnoj regiji C3, Cz, C4, Cp3, Cp4, P3, Pz, P4 gdje je P300 signal najdominantniji kako je već opisano u prethodnim poglavljima. Primjena auditornih stimulacija u predloženoj eksperimentalnoj paradigmi uvjetovala je da se dvije elektrode T7 i T8 smjeste na temporalne regije koje se nalaze iznad ušiju a koje su zadužene za obradu zvučnih podražaja. GND i REF elektroda nalaze se iza lijevog odnosno desnog uha subjekta.

4.2. Analiza nezavisnih komponenti

U nastavku ovog rada prilikom obrade EEG podataka prikupljenih opisanom eksperimentalnom paradigmom koristit će se analiza nezavisnih komponenti. Navedena optimizacijska metoda iz grupe BSS algoritama često je korištena u obradi EEG signala zbog sposobnosti rastavljanja multidimenzionalih signala na nezavisne komponente koje nisu nužno ortogonalne kao u slučaju PCA dekompozicije, a koje predstavljaju vrlo dobre estimate izvora neurološke aktivnosti. Prvenstveno je navedeni algoritam razvijen kao rješenje za cocktail-party problem, u kojem se grupa od *m* osoba koje se mogu promatrati kao nezavisni izvori zvučnih signala nalazi na zabavi na kojoj je postavljeno *m* mikrofona čija lokacija nije poznata, a koji snimaju razgovor između prisutnih gostiju [80], [92]. Svaki od mikrofona zapravo mjeri superpoziciju svih nezavisnih zvučnih izvora, tako da je snimljene signale moguće opisati sljedećim linearnim multivarijabilnim modelom:

$$\begin{aligned} \overline{x_1} &= a_1^1\overline{z_1} + a_1^2\overline{z_2} + \cdots + a_1^m\overline{z_m} \\ \overline{x_2} &= a_2^1\overline{z_1} + a_2^2\overline{z_2} + \cdots + a_2^m\overline{z_m} \\ &\vdots \\ \overline{x_m} &= a_m^1\overline{z_1} + a_m^2\overline{z_2} + \cdots + a_m^m\overline{z_m} \end{aligned} \tag{4.1}$$

u kojem vektori $\overline{x_i} \in R^{1\,x\,n}$ predstavljaju snimljene podatke, $\overline{z_i} \in R^{1\,x\,n}$ vektore koji definiraju nezavisnu komponentu svake osobe, a skalari a_j^k faktore koji opisuje utjecaj *k*-te nezavisne komponente $\overline{z_k}$ na snimljene podatke $\overline{x_j}$ *j*-tog mikrofona. Već iz same definicije algoritma vidljivo je da se ICA može vrlo lako primijeniti i na EEG signale, gdje se pojedini izvori neuroloških reakcija mogu opisati vektorima $\overline{z_i}$ koji međusobnom superpozicijom čine EEG mjerenja opisana vektorima $\overline{x_i}$ odnosno modelom (4.1). Svođenjem (4.1) na matrični oblik dobiva se sljedeći izraz:

$$\boldsymbol{X} = \boldsymbol{AZ}, \tag{4.2}$$

gdje su prikupljena mjerenja $\boldsymbol{X} \in \boldsymbol{R^{mxn}}$ definirana sljedećim matematičkim izrazom:

$$\boldsymbol{X} = \begin{bmatrix} \overline{X}_1 \\ \overline{X}_2 \\ \vdots \\ \overline{X}_m \end{bmatrix} = \begin{bmatrix} x_1^1 & x_1^2 & \dots & x_1^n \\ x_2^1 & x_2^2 & \dots & x_2^n \\ \vdots & \vdots & \ddots & \vdots \\ x_m^1 & x_m^2 & \dots & x_m^n \end{bmatrix}, \tag{4.3}$$

gdje je matrica $\boldsymbol{Z} \in \boldsymbol{R^{mxn}}$, matrica nezavisnih komponenti odnosno matrica nezavisnih izvora

neurološke aktivnosti:

$$\boldsymbol{Z} = \begin{bmatrix} \bar{Z}_1 \\ \bar{Z}_2 \\ \vdots \\ \bar{Z}_m \end{bmatrix} = \begin{bmatrix} z_1^1 & z_1^2 & \dots & z_1^n \\ z_2^1 & z_2^2 & \dots & z_2^n \\ \vdots & \vdots & \ddots & \vdots \\ z_m^1 & z_m^2 & \dots & z_m^n \end{bmatrix}, \tag{4.4}$$

gdje $\boldsymbol{n}$ predstavlja broj vremenskih uzoraka EEG mjerenja, a $\boldsymbol{m}$ ukupan broj EEG elektroda.

Superpozicijska matrica $\boldsymbol{A}$ kvadratna je matrica dimenzije $\boldsymbol{m}$, koja je određena sljedećim izrazom:

$$\boldsymbol{A} = \begin{bmatrix} a_{\boldsymbol{1}}^{\boldsymbol{1}} & a_{\boldsymbol{1}}^{\boldsymbol{2}} & \cdots & a_{\boldsymbol{1}}^{\boldsymbol{m}} \\ a_{\boldsymbol{2}}^{\boldsymbol{1}} & a_{\boldsymbol{2}}^{\boldsymbol{2}} & \cdots & a_{\boldsymbol{2}}^{\boldsymbol{m}} \\ \vdots & \vdots & \ddots & \vdots \\ a_{\boldsymbol{m}}^{\boldsymbol{1}} & a_{\boldsymbol{m}}^{\boldsymbol{2}} & \cdots & a_{\boldsymbol{m}}^{\boldsymbol{m}} \end{bmatrix}, \tag{4.5}$$

čije vrijednosti u redcima opisuju jačinu odnosno utjecaj svakog izvora neurološke aktivnosti na *k*-tu elektrodu postavljenu na tjeme subjekta. Za očekivati je da će u slučaju normaliziranih podataka izvor moždane aktivnosti *j* biti najizraženiji na mjerenom signalu elektrode *k* koja je prostorno najbliže navedenom izvoru, tako da će superpozicijski faktor elektrode *k* a_k^j povezan s najbližom izvorom biti veći od faktor a_k^l izvora *l* čija je udaljenost od elektrode *k* mnogo veća.

Pitanje na koje ICA pokušava dati odgovor moguće je formulirati sljedećom rečenicom: dali je iz snimljenih podataka $\boldsymbol{X}$ moguće rekonstruirati nezavisne izvore neurološke aktivnosti, iako je fizikalnost sustava nedefinirana odnosno algoritmu nisu dostupne informacije o rasporedu elektroda kao ni osnovne informacije o funkcionalnosti mozga. Drugim riječima ICA „na slijepo“ nastoji pronaći *m*-dimenzionalnu kvadratnu matricu $\boldsymbol{W}$ koja množena sa mjerenjima $\boldsymbol{X}$ daje najbolji mogući estimat $\boldsymbol{Y}$ matrice nezavisnih komonenti $\boldsymbol{Z}$, odnosno

$$\boldsymbol{Y} = \boldsymbol{W}\boldsymbol{X}, \tag{4.6}$$

U slučaju idealne estimacije vrijede sljedeće jednakosti: $\boldsymbol{Y} = \boldsymbol{Z}, \boldsymbol{W} = \boldsymbol{A}^{-1}$.

Iako smo mjereni električni signal svake elektrode $\overline{x_i}$, nezavisne komponente $\overline{z_i}$ i estimate nezavisnih komponenti $\overline{y_i}$ intuitivno definirali kao vektore, svaki od vektora može se promatrati kao slučajna varijabla X_i, Z_i, Y_i, što znači da ih možemo definirati kao stupčane vektore sa *m* slučajnih varijabli sljedećeg oblika:

$$\bar{X} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_m \end{bmatrix} \quad \bar{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_m \end{bmatrix} \quad \bar{Z} = \begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_m \end{bmatrix}, \tag{4.7}$$

odnosno (4.2) i (4.6) prikazati u novom obliku, u kojima je vektorski zapis zamijenjen slučajnim varijablama:

$$\bar{X} = \boldsymbol{A}\bar{Z};\ \bar{Y} = \boldsymbol{W}\bar{X}, \tag{4.8}$$

Iz (4.8) vidimo zapravo da je ICA optimizacijski algoritam, koji pokušava estimirati matrice $\boldsymbol{W}$ i $\boldsymbol{Y}$ odnosno vektor slučajnih varijabli $\bar{Y}$, tako da su sve estimacije nezavisnih komponenti $\bar{y}_j$ ili Y_j međusobno maksimalno statistički nezavisne, uz sljedeće pretpostavke:

- izvori nezavisnih komponenti Z_i statistički su nezavisni
- izvori nezavisnih komponenti Z_i imaju distribuciju koja nije normalna gaussova distribucija

Oba uvjeta nužni su za definiranje funkcije cilja optimizacijskog algoritma, odnosno funkcije koja će omogućiti razdvajanje podataka $\boldsymbol{X}$ na nezavisne komponente matrice $\boldsymbol{Y}$. Iako je prvi uvjet intuitivan i logičan, motivaciju za drugi uvjet treba potražiti u centralnom graničnom teoremu (CGT). Naime, prema centralnom graničnom teoremu, zbrajanjem slučajnih nezavisnih varijabli Z_i (što je sama definicija ICA algoritma prema (4.8)) distribucija vjerojatnosti zbroja nezavisnih varijabli poprima oblik gaussove distribucije sa srednjom vrijednošću μ i standardnom devijacijom σ. Drugim riječima, zbroj dviju i više nezavisnih komponenti sa ne-gaussovom distribucijom, biti će više nalik gaussovoj distribuciji nego svaka komponenta zasebno. Iz navedenoga moguće je preformulirati definiciju ICA metode kao matematičkog alata koji iz nekog skupa podataka slučajnih varijabli $\boldsymbol{X}$, estimira matricu $\boldsymbol{W}$ i matricu nezavisnih komponenta $\boldsymbol{Y}$, tako da distribucija slučajnih varijabli Y_j bude maksimalno udaljena od normalne distribucije odnosno da distribucije nezavisnih komponenti budu maksimalno moguće ne-gaussove.

Kao mjera ne-gaussivnosti neke distribucije slučajne varijable Y često se koristi entropija $H(Y)$ koja definira stupanj različitih informacija unutar promatrane slučajne varijable. Razlog tome leži u činjenici da je entropija slučajne varijable maksimalna, ako prati gaussovu distribuciju, te u slučaju jedinične standardne devijacije iznosi $\ln\sqrt{2\pi e}$, zbog čega se razlika entropija gaussove i promatrane slučajne varijable odnosno negentropija $J(Y)$ definira sljedećim izrazom:

$$J(\bar{Y}) = H(Y_{Gauss}) - H(\bar{Y}) = \ln\sqrt{2\pi e} - H(\bar{Y}), \tag{4.9}$$

može koristiti kao ICA optimizacijska funkcija. Kako bi se optimizacijska metoda proširila na ostatak slučajnih varijabli definiranih vektorom $\bar{Y}$ (4.7), ICA optimizacija koristi mjeru zajedničke informacije (engl. *Mutual Information*, MI) $I(\bar{Y})$ koja predstavlja količinu informacije koju dvije slučajne varijable međusobno dijele, tako da je konačna ICA optimizacijska funkcija opisana slijedećim izrazom:

$$I(\bar{Y}) = I(Y_1, Y_2, \dots, Y_m) = J(\bar{Y}) - \sum_{i=1}^{m} J(Y_i). \tag{4.10}$$

Iz (4.10) vidljivo je da minimizacija zajedničke informacije, odnosno ravnine na kojoj je zajednička informacija projiciranih signala opisanih matricom $\boldsymbol{X}$ minimalna, ekvivalentna pronalasku vektora na kojima je razlika entropija (negantropija) maksimalna [93].

4.3. Obrada mjerenih signala neurološke aktivnosti

Sva prikupljena mjerenja pohranjena su u *.gdf* formatu koji je potrebno učitati u MATLAB razvojno okruženje radi daljnje analize. U tu svrhu korišten je EEGLAB [94], [95] alatni paket koji učitana mjerenja sprema u karakterističnu EEG strukturu unutar koje se nalaze sve relevantne informacije o mjerenju kao što je mjereni signal, stimulacijski markeri i informacija o njihovoj vremenskoj lokaciji, raspored elektroda, nezavisne komponente kao rezultat ICA algoritma, itd. Povrh navedenog učitavanja mjerenja, navedeni alatni paket svojim funkcijama olakšava manipuliranje, obradu i analizu mjerenih neuroloških reakcija.

Prvi korak nakon učitavanja podataka primjena je pojasno-propusnog filtera s donjom graničnom frekvencijom od 0.2 Hz i gornjom graničnom frekvencijom od 40 Hz na mjereni signal čime je uklonjen dio spektra koji nije relevantan za P300 signal. Filtriranje je izvedeno pomoću MATLAB funkcije *filtfilt()* koja signal filtrira u oba smjera (smjer porasta vremena i obrnuto) zbog čega filtrirani signal nema fazno kašnjenje.

Tako filtrirani signal u sljedećem koraku biti će razdijeljen na pripadajuće segmente, npr. mjerenje u kojem je potrebno napisati riječ STOP kao u primjeru na slici 3.1 rastavljeno je na četiri segmenta. U tu svrhu koriste se markeri *OVTK_StimulationId_SegmentStart (33271)* i *OVTK_StimulationId_SegmentStop (33272)* koji označavaju početak i kraj svakog pojedinog

segmenta.

Kao što je rečeno u drugom poglavlju, prilikom provedbe eksperimenta u mjerenjima se često pojavljuju signali velikih amplituda koji nisu povezani s neurološkom reakcijom korisnika, već je njihov izvor najčešće električna aktivnost nastala pomicanjem mišića (npr. očiju, kapaka, vrata, rad srca i sl.), a čija magnituda može u potpunosti prekriti korisni signal. S obzirom da se u navedenoj eksperimentalnoj paradigmi radi o ne-iterirajućem (single-trial) principu traženja ciljanog slova, navedeni artefakti dodatno će otežati ili u potpunosti onemogućiti ispravnu klasifikaciju mjerenog singla. Moguće rješenje je uklanjanje artefakta iz mjerenog signala, za što će se u ovom radu koristiti analiza nezavisnih komponenti i ICLabel alat [96] kao dio EEGLAB paketa. ICLabel naziv je klasifikatora baziranog na neuronskoj mreži koji na temelju prostorno-vremenskih karakteristika nezavisnih komponenti dobivenih primjenom ICA algoritma na EEG signal određuje tip izmjerene reakcije odnosno klasificira dobivene nezavisne komponente u jednu od sljedećih sedam klasa: neurološka aktivnost, mišićna aktivnost, pomicanje očiju, rad srca, šum uzrokovan naponom napajanja mjernog uređaja, šum uzrokovan lošim kontaktom između elektrode i tjemena, te ostali izvori. Uz samo klasificiranje nezavisnih komponenti, ICLabel prikazuje i vjerojatnost odnosno sigurnost da promatrana nezavisna komponenta pripada odgovarajućoj klasi.

Prvi korak u uklanjanju neželjene aktivnosti je računanje nezavisnih komponenti na svakom prethodno definiranom segmentu, za što je korištena Infomax ICA [97]. Rezultat dekompozicije mjerenog segmenta u trajanju od otprilike 22 sekunde je 16 nezavisnih komponenti klasificiranih u sedam prethodno spomenutih klasa. U ovom radu uklonjene su nezavisne komponente koje sa sigurnošću višom od 90% pripadaju klasama mišićna aktivnost i pomicanje očiju. Visoka razina sigurnosti potencijalno će spriječiti uklanjanje komponenti koje mogu imati pozitivan utjecaj na klasifikaciju ciljanih i ne-ciljanih podražaja. Uklanjanje komponenti povezanih s artefaktima iz mjerenog EEG signala osigurano je kroz postavljanje svih vrijednosti stupaca superpozicijske matrice definirane (4.5) s indeksom koji odgovara identificiranim nezavisnim komponentama na nulu; npr. ako je iz signala potrebno ukloniti petu i devetu nezavisnu komponentu tada sve vrijednosti petog i devetog stupca superpozicijske matrice $\boldsymbol{A}$ iznose nula. Projiciranjem nezavisnih komponenti u originalni prostor odnosno prostor elektroda, novodefinirana superpozicijska matrica množi se s matricom nezavisnih komponenti $\boldsymbol{Z}$ te je rezultat signal u originalnom prostoru na koji nisu projicirane komponente povezane s artefaktima. Pored navedenog važno je napomenuti da se u slučaju lošeg kontakta između elektrode i tjemena cijeli segment potpuno uklanja iz daljnje analize.

Nakon što su iz segmenta uklonjeni svi artefakti, za potrebe validacije paradigme iz svakog pojedinog segmenta potrebno je izdvojiti dio mjerenja oko ciljane stimulacije koji se naziva epoha. Iz tog razloga, ekstrahiran je dio mjerenja u trajanju od pet sekundi, a koji počinje tri sekunde prije ciljane stimulacije te završava dvije sekunde nakon što je korisniku prezentirana ciljana stimulacija. U svakoj epohi nalaze se neurološke reakcije na tri uzastopne ne-ciljane stimulacije (prve tri sekunde epohe), zatim slijedi EEG mjerenje duljine jedne sekunde povezano sa reakcijom na ciljano slovo, te završno još jedna neurološka reakcija na ne-ciljanu stimulaciju u trajanju od jedne sekunde. Sve epohe poslagane su u jednu matricu s brojem redaka koji odgovara broju aktivnih elektroda, dok broj stupaca odgovara ukupnom broju uzoraka koji je jednak umnošku vremena trajanja epohe (pet sekundi), frekvencije uzorkovanja (512 Hz) i broju ekstrahiranih epoha odnosno broju prikupljenih segmenta.

4.4. Rezultati mjerenja eksperimentalne paradigme s povratnom informacijom

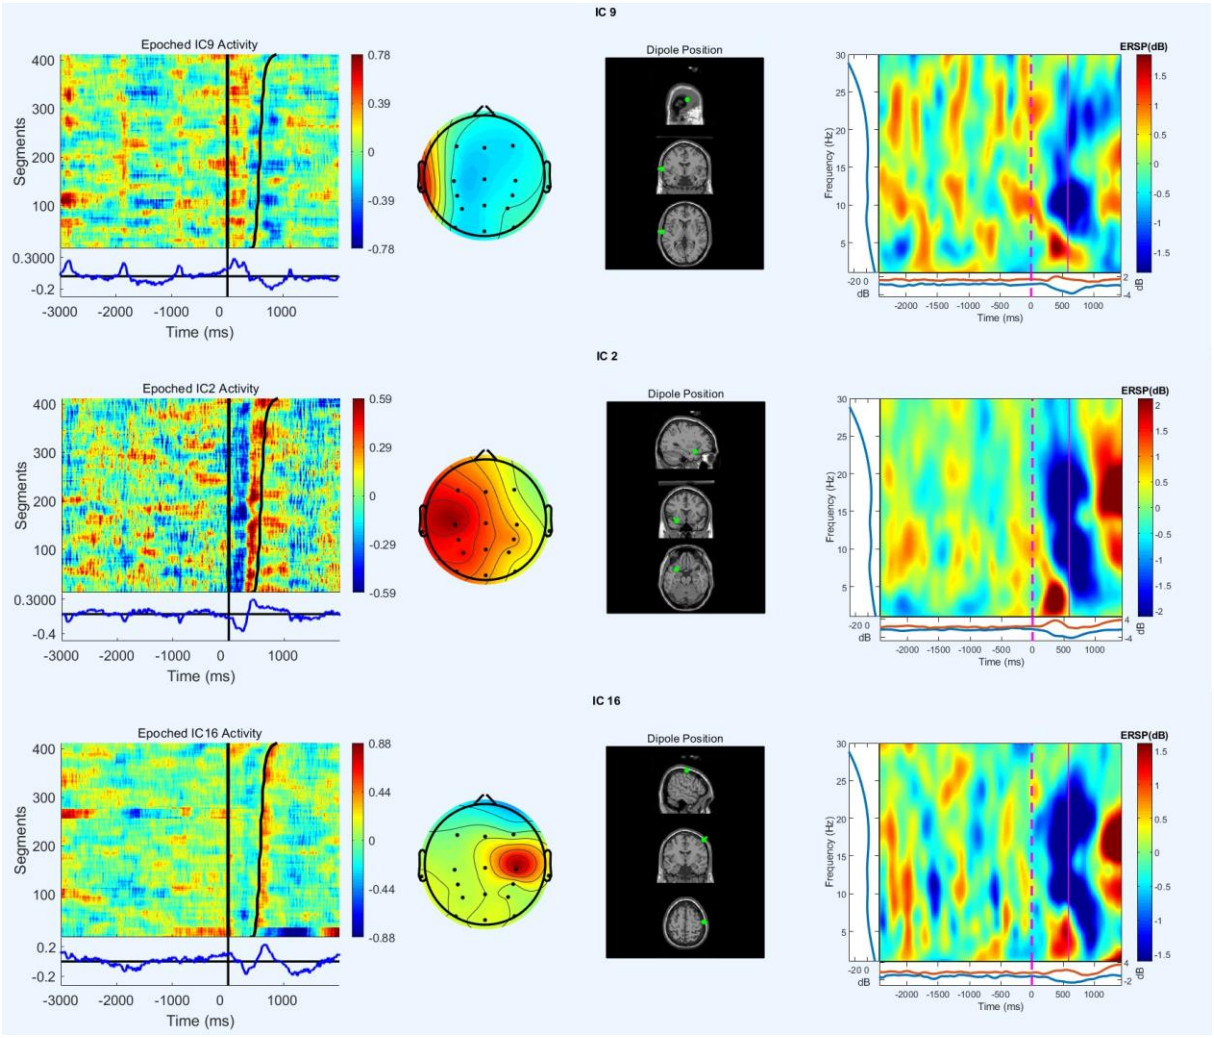
Mjerenja prikupljena provedbom eksperimentalne paradigme s povratnom informacijom na pet subjekata obrađena su prema prethodno opisanom postupku tako da je rezultat obrade matrica s ekstrahiranim epohama duljine pet sekundi. Kako je već istaknuto, ideja je da se daljnjom obradom i analizom epoha detektira evidentna razlika između ciljanih i ne-ciljanih stimulacija, te još važnije postojanost P300 reakcije na ciljane stimulacije. U tu svrhu Infomax ICA primijenjena je na matrici epoha, čiji je rezultat novih 16 nezavisnih komponenti od kojih neke pripadaju P300 komponentama [98], [99].

Iz dobivenih komponenti računaju se vremenske, prostorne i spektralne karakteristike s ciljem definiranja jasnih razlika između ciljane i ne-ciljane stimulacije [100]. Na slikama 4.3 do 4.9 prikazane su navedene karakteristike nezavisnih komponenti neurološke aktivnosti za prvog i drugog subjekta. U prvom stupcu nalazi se vremenska distribucija nezavisnih komponenti prikazana na način da se na y-os nalaze sve neurološke aktivnosti iz dobivenih epoha, x-os predstavlja vrijeme, dok je mjereni signal moždane aktivnosti prikazan pomoću palete boja, čija se legenda nalazi na rubu vremenskog prikaza. Ispod prikaza neurološke aktivnosti za svaku pojedinu epohu nalazi se usrednjena aktivnost po svim epohama na istom vremenskom intervalu od pet sekundi, a koja omogućuje dodatnu usporedbu neurološke aktivnosti iz predložene paradigme sa sličnim istraživanjima u kojima je relevantna moždana aktivnost uvijek promatrana kroz usrednjene signale dobivene iz višestrukog mjerenja odziva

na ciljane stimulacije. Kako je već napomenuto u poglavlju 4.3 unutar epohe prikazane su reakcije na četiri ne-ciljane stimulacije koje su korisniku prezentirane u sljedećim vremenskim trenutcima: -3000, -2000, -1000 i 1000 ms, te neurološku reakciju na ciljani podražaj u vremenu nula sekundi označeno podebljanom crnom vertikalnom linijom. Dodatna podebljana crna monotono rastuća linija na intervalu od 300 ms do 850 ms označava vremenski trenutak u kojem je korisnik pritisnuo jednu od dozvoljenih tipki odnosno vremenski trenutak u kojem je došlo do reakcije korisnika na ciljanu stimulaciju. Strogo rastuća krivulja reakcije uvjetovana je time da epohe nisu kronološki poredane već su uzlazno prezentirane prema vremenskom kašnjenju reakcije od najmanjeg prema najvećem. Dodatno je potrebno napomenuti da se sve epohe u kojima nije pronađena reakcija subjekta na ciljani podražaj odnosno gdje nije pronađen marker *OVTK_StimulationId_Button1_Pressed*, uklonjene iz daljnje analize.

Drugi i treći stupac prikazuju prostornu distribuciju nezavisnih komponenti odnosno prostornu lokalizaciju izvora neurološke reakcije opisane dobivenom nezavisnom komponentom. Tako je u drugom stupcu prikazana prostorna distribucija komponenti s obzirom na ravninu tjemena subjekta, dok je u trećem stupcu na temelju mjerenih EEG signala koji predstavljaju projekciju moždane aktivnosti na tjeme, određena potencijalna 3D lokacija izvora promatrane neurološke reakcije. Navedena 3D lokacija dobivena je uz pomoć DIPFIT funkcija [95], [101] koje na temelju EEG signala rješavanjem inverznog problema [102] estimiraju poziciju i orijentaciju neuroloških reakcija opisanih dobivenim nezavisnim komponentama uz pojednostavljenu sliku ukupnog procesa. Kako je broj izvora neuroloških reakcija koje mogu generirati izmjerene električne signale gotovo neograničen, ideja inverzne lokalizacije je kroz optimizacijski algoritam pronaći područje mozga čija će aktivnost na temelju pretpostavke o dipolnoj distribuciji izvora neurološke aktivnosti [103] kao i električnog modela glave, tjemena i skalpa najbolje moguće opisati izmjereni EEG signal ili u ovom slučaju dobivene nezavisne komponente.

U posljednjem četvrtom stupcu u vremensko-frekvencijskoj domeni prikazana je promjena energije signala nezavisne komponente uzrokovane stimulacijama (*engl. Event Related Spectral Perturbation, ERSP*) [104]. Prvi korak pri izračunu spektralnih karakteristika signala je računanje vremensko-frekvencijske distribucije nezavisne komponente na svim epohama te njeno usrednjavanje. Određivanje vremensko-frekvencijske distribucije primjenom EEGLAB paketa moguće je korištenjem Fourierove transformacije s funkcijom vremenskog prozora (*engl. Short-time Fourier transform, STFT*) uz primjenu Hanningova prozora ili Wavelet transformacijom. Primjenom Wavelet transformacije na prikupljenim epohama dobiven je



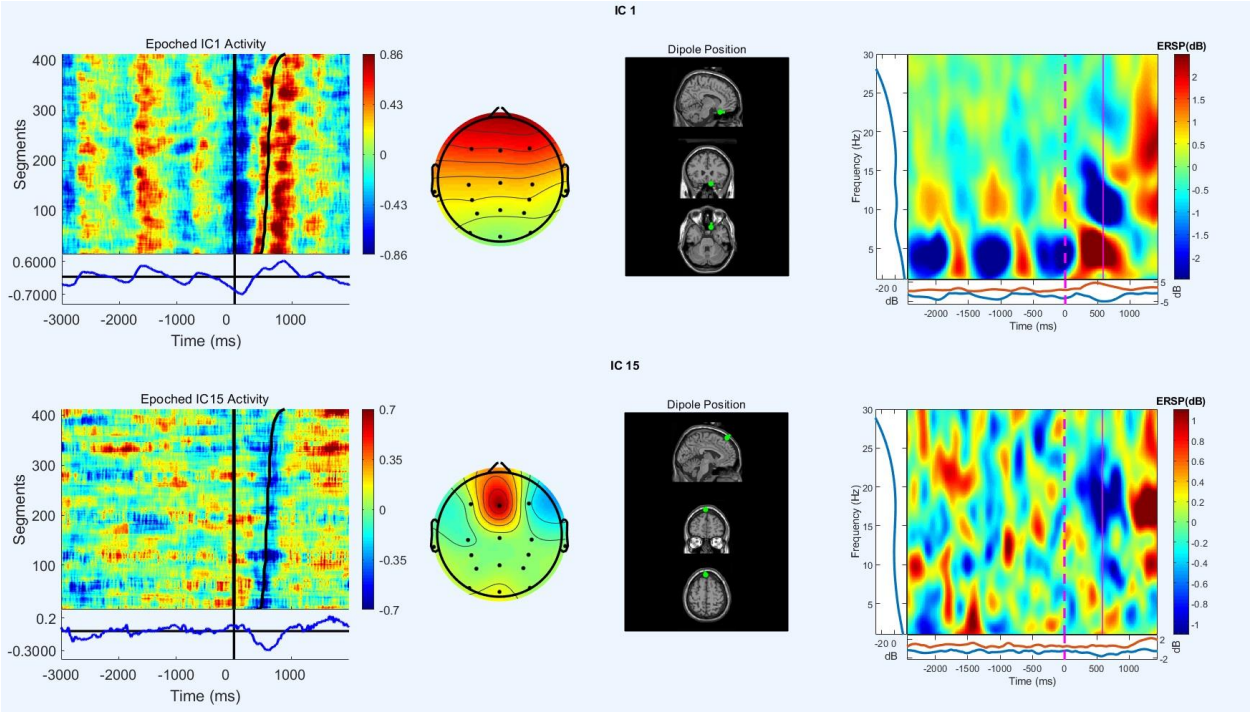
Slika 4.3. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti prvog subjekta lokaliziranih u temporalnoj i centralno-temporalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom. Nezavisna komponenta 9 (prvi red) locirana u temporalnoj regiji zadužena je za obradu auditornih podražaja, dok su nezavisne komponente 2 i 16 (drugi i treći red) neurološke reakcije povezane s motoričkom aktivnosti odnosno pritiskanjem tipke.

prilično kontinuiran prikaz vremensko-frekvencijske distribucije promatranih nezavisnih komponenti s frekvencijskom rezolucijom od 0.1 Hz odnosno temporalnom rezolucijom od 20ms.

Iako se iz vremensko-frekvencijske distribucije mogu dobiti informacije o stimulacijom uzrokovanoj sinkronizaciji odnosno porastu amplitude signala (*engl. Event Related Synchronization, ERS*) i desinkronizaciji odnosno smanjenju amplitude signala (*engl. Event Related Desynchronization, ERD*) na određenom frekvencijskom području (npr. alfa (8-12 Hz),

beta (13-30 Hz) i theta (4-8 Hz) moždani valovi), frekvencijska područja u kojima je došlo do promjene energije signala dodatno su istaknuta oduzimanjem trenutne energije signala u svakom pojedinom vremenskom trenutku vremensko-frekvencijskog prikaza. Česta je potreba u analizi neuroloških reakcija detektirati razliku između ciljane i ne-ciljane stimulacije, zbog čega se za računanje trenutne energije koriste samo mjerenja s negativnim vremenima, odnosno svi uzorci izmjereni prije prezentiranja ciljane stimulacije i evociranja neurološkog odziva (u ovom slučaju svi uzorci od -3000ms do 0ms). Za potrebe ove analize kako bi se jednako vrednovali svi vremenski trenutci, računanje trenutne energije izvršeno je za vremenske trenutke i prije i poslije ciljane stimulacije. Frekvencijski spektar trenutne energije prikazan je s lijeve strane, dok se ispod ERSP grafa nalazi usrednjeni vremenski prikaz porasta energije signala (crvena linija) na rastućem frekvencijskom području i smanjenja energije signala (plava linija) na padajućem frekvencijskom području. Ovakvim prikazom moguće je uočiti kako je čest slučaj da u istom vremenskom trenutku unutar nezavisne komponente koja opisuje određenu neurološku reakciju imamo sinkronizaciju signala u delta frekvencijskom području i desinkronizaciju u alfa i beta frekvencijskom području, o čemu će više riječi biti u nastavku. Dodatnu pomoć pri analizi vremensko-frekvencijske distribucije nezavisne komponente osigurava isprekidana vertikalna linija koja predstavlja trenutak u kojem je ciljana stimulacija prezentirana subjektu, te puna vertikalna linija koja predstavlja srednje vrijeme pri kojem je došlo do pritiska tipke od strane subjekta.

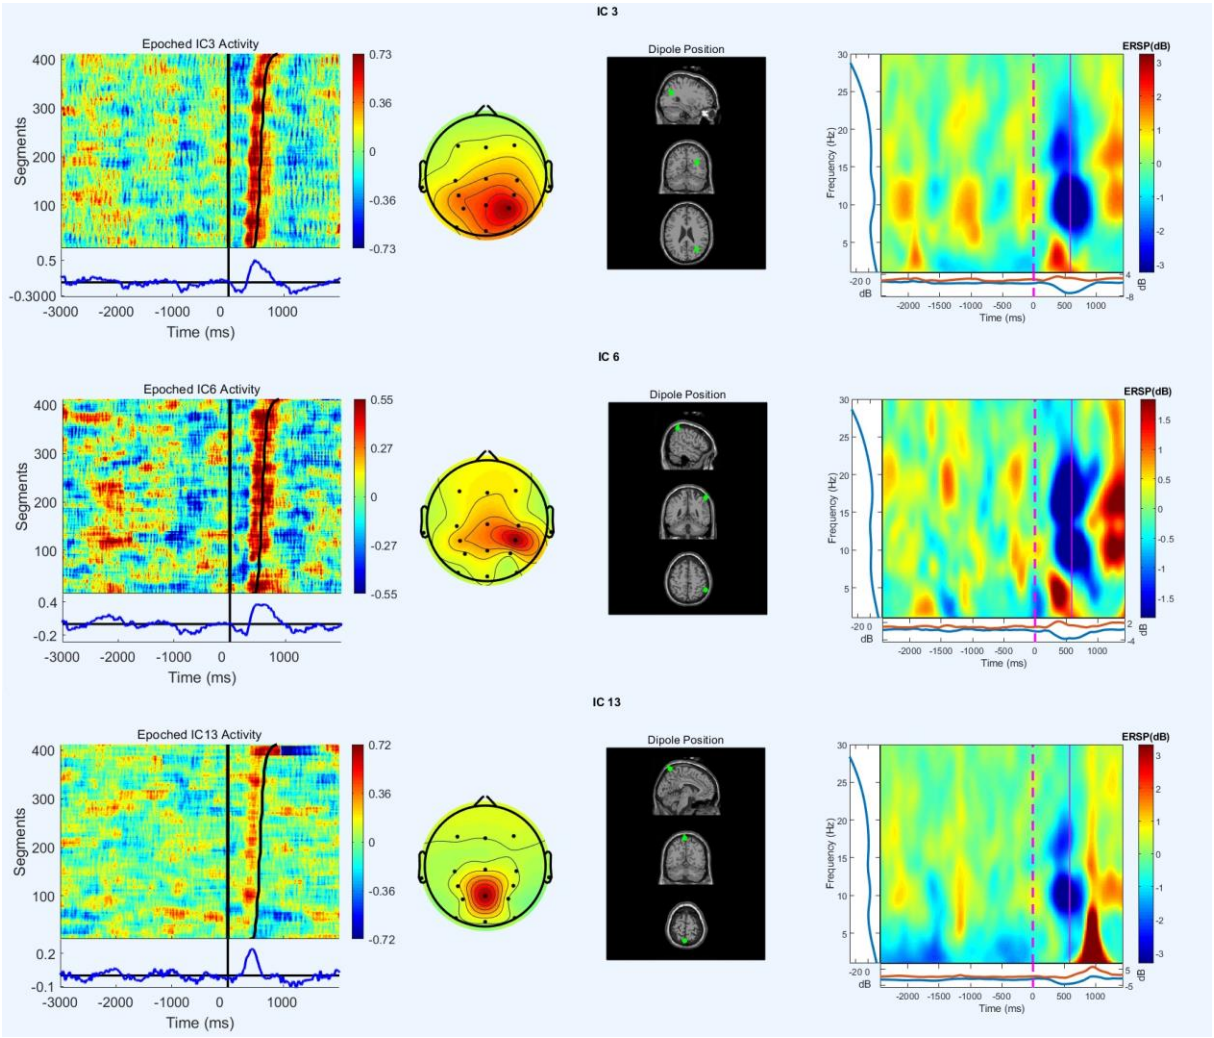
Nezavisne komponente dobivene analizom mjerenog EEG signala kod prvog subjekta koje predstavljaju estimacije nezavisnih generatora moždane reakcije na niz od pet stimulacija u razmaku od jedne sekunde podijeljene su prema prostornoj distribuciji na centralno-temporalne (slika 4.3), frontalne (slika 4.4), centralno-parijetalne komponente (slika 4.5). Promatrajući dobivene neurološke reakcije prema vremenskom redoslijedu aktivacije počinjemo od nezavisne komponente 9 koja se nalazi u lijevoj temporalnoj regiji mozga. Navedena regija kod većine ljudi predstavlja dominantnu regiju i zadužena je pretežno za detekciju i obradu auditornih podražaja, što je vidljivo iz porasta amplitude signala nedugo nakon auditorne stimulacije (cca. 100-150 ms) neovisno o tome radi li se o ciljanoj ili ne-ciljanoj stimulaciji. Opažena neurološka reakcija može se objasniti kao proces interpretacije auditornog podražaja. Promatrajući samo reakciju na ciljani podražaj vidimo da početni porast signala identičan ostalim ne-ciljanim stimulacijama, međutim duljina reakcije kao i intenzivniji pad amplitude ukazuje na kompleksniju neurološku reakciju u odnosu na ne-ciljane stimulacije. Osim toga, intenzitet neurološke reakcije na ciljani podražaj uzrokovao je gotovo kompletni nedostatak



Slika 4.4. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti prvog subjekta lokaliziranih u frontalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom.

reakcije na sljedeću stimulaciju u nizu. Dodatne informacije o samoj dinamici neurološke reakcije otkriva nam ERSP pomoću kojeg uočavamo sinkronizaciju u theta području s maksimumom na frekvenciji od 5 Hz i vremenskim odmakom od 400 ms nakon stimulacije kao i desinkornizaciju (ERD) u alfa području sa maksimumom između 10 i 11 Hz. Porast signala u theta području povezuje se s povećanom koncentracijom subjekta kao i složenijim zadatkom koji subjekt obavlja kao što je u ovom slučaju analiza opaženih auditornih podražaja. Desinkronizaciju signala u alfa području moguće je objasniti kroz činjenicu da pojedine regije mozga koriste alfa valove kao informaciju o trenutnoj aktivnosti regije odnosno pojačana prisutnost alfa valova sugerira trenutno mirovanje tj. neaktivnost, dok desinkronizacija alfa valova kao u slučaju prikazanom na slici 4.3. sugerira trenutnu aktivnost promatrane regije. Pretpostavka je da se tim procesom dopušta ili blokira razmjena informacija između različitih regija koje zajedno sudjeluju u promatranom neurološkom procesu [105], [106].

Daljnja obrada registriranih auditornih podražaja prema [107] odvija se u frontalnoj regiji, točnije u superiornom frontalnom sulkusu unutar kojeg dolazi do interpretacije detektiranog slova. Navedena aktivnost u frontalnoj regiji vidljiva je iz analize nezavisne komponente 1, gdje je postojana neurološka reakcija vidljiva i na ne-ciljanim stimulacijama, dok je reakcija na



Slika 4.5. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti prvog subjekta lokaliziranih u parijetalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom. Istaknute komponente na temelju prikazanih karakteristika gotovo sigurno pripadaju P3b odzivu na ciljanu stimulaciju.

ciljanu stimulaciju koja prethodi pritisku tipke puno dugotrajnija i izraženija. Promatrana neurološka aktivnost također je dio P300 signala, te se u literaturi često označava kao P2a/P3f komponenta [108]. Analiza promjene energije signala u frekvencijskom spektru nezavisne komponente ukazuje na slično ponašanje kao i slučaju nezavisne komponente 9, u kojem dolazi do naizmjenične desinkronizicije odnosno sinkronizacije u delta i theta području neovisno o tipu stimulacije, dok je promjena spektra ipak izraženija kod reakcije na ciljanu stimulaciju. Za sve prikazane stimulacije jasno se može uočiti usklađenost sinkronizacije u theta području i desinkronizacije u alfa području i obrnuto. Promatrajući beta frekvencijsko područje moguće

je uočiti početak sinkronizacije na oko 1000 ms od trenutka prezentiranja ciljane stimulacije s maksimumom na frekvenciji od cca. 19 Hz, što prema dosadašnjim istraživanjima [107] ukazuje na obavljanje zadataka vezanih uz procjenu stimulacija i kognitivno planiranje daljnjih odluka. Osim navedene komponente 1, nezavisna komponenta 15 prikazana na slici 4.4. također je aktivna u frontalnoj regiji odnosno dorsolateralnom prefrontalnom korteksu (DLPFC). Za razliku od komponente 1 koja je aktivna u svim stimulacijama, nezavisna komponenta 15 pokazuje značajni negativni polaritet signala neposredno prije i tijekom pritiskanja tipke. Pogledom na spektralne karakteristike signala uočljiva je desinkronizacija signala u beta području oko trenutka kada je subjekt aktivno pritiskao tipku, te izražena sinkronizacija u gotovo identičnom frekvencijskom području oko 500 ms nakon pritiska. Slične promjene spektra kao i kod nezavisne komponente 1 mogle bi ukazivati na to da navedene nezavisne komponente zajednički sudjeluju u analizi značenja stimulacije. Međutim na umu je potrebno imati informaciju o tome da je važna funkcija DLPFC također planiranje motoričkih radnji, zbog čega bi navedena komponenta mogla biti dio neurološke aktivnosti na željenu motoričku reakciju. Aktivnost komponente koja je vremenski usklađena s pritiskom tipke, te desinkronizaciju i sinkronizaciju u beta području možemo argumentirati i na način da je navedena komponenta povezana sa samom motoričkom radnjom na način kao što su komponente 2 i 16.

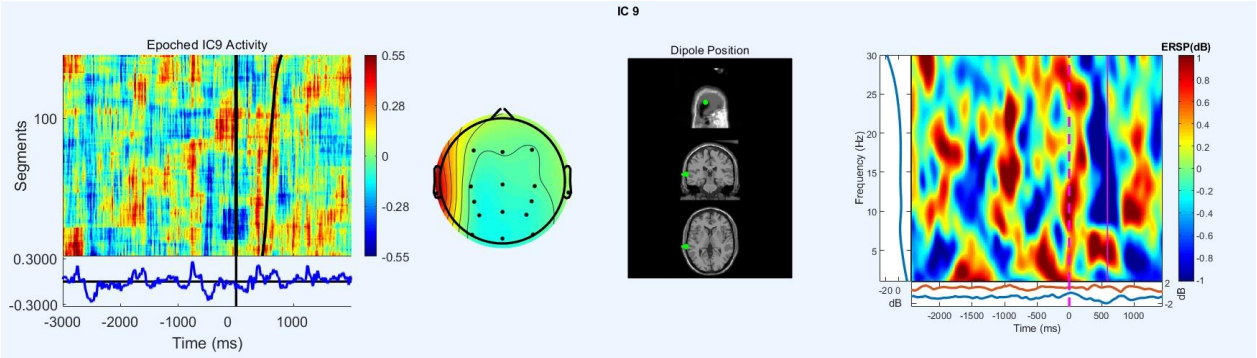
Procjena stimulacije u frontalnoj regiji uzrokovala je daljnje neurološke reakcije definirane nezavisnim komponentama 3, 6 i 13 (slika 4.5) u parijetalnoj i centralno-parijetalnoj regiji mozga koje su direktno povezane s P3b komponentom. Kao što je već napomenuto P3b neurološka reakcija, reakcija je na smislenu odnosno ciljanu stimulaciju koja zahtjeva daljnju usredotočenost ili mentalnu aktivnost kao npr. pritisak tipke, te bi prema dosadašnjim istraživanjima trebala biti osnovni signal za uspješnu klasifikaciju ciljanih i ne ciljanih stimulacija u predloženoj paradigmi. Iako se u početku vjerovalo kako postoji samo jedan generator P3b komponente čija je lokacija definirana unutar parijetlane moždane regije [107], [108], daljnja su istraživanja pokazala prisutnost velikog broja komponenti s temporalnim svojstvima nalik P3b komponenti čija lokacija nije ograničena samo u navedenim regijama, već je generiranje P3b signala kompleksan proces koji također uključuje frontalnu i temporalnu regiju kao i basalne ganglije i veze između talamusa i korteksa [107]. Sa slike 4.5 vidljivo je da nezavisne komponente 3 i 6 dijele gotovo identična svojstva odnosno identične temporalne, prostorne i vremensko-frekvencijske karakteristike. Obje komponente imaju gotovo identičan porast amplitude oko 300 ms nakon ciljane stimulacije sa sličnom prostornom distribucijom u

desnoj parijetalnoj regiji, te identičnom promjenjivošću frekvencijskog spektra s time da je sinkronizacija i desinkronizacija u alfa i beta frekvencijskim područjima puno izraženija kod nezavisne komponente 6. Promatrajući nezavisnu komponentu 13 možemo uočiti da je porast amplitude nakon ciljane stimulacije ipak nešto brži te je porast detektiran već nakon 200 ms od trenutka ciljane stimulacije. Prostorna distribucija komponente ukazuje na poklapanje s centralnom parietalnom elektrodom, dok vremensko-frekvencijska analiza osim na već poznatu desinkronizaciju u alfa i beta području ukazuje na snažnu sinkronizaciju signala na delta, theta i djelomičnom alfa (od 8-10 Hz) području od 600 ms do 1200 ms nakon ciljane stimulacije, čije ponašanje trenutno nije moguće objasniti.

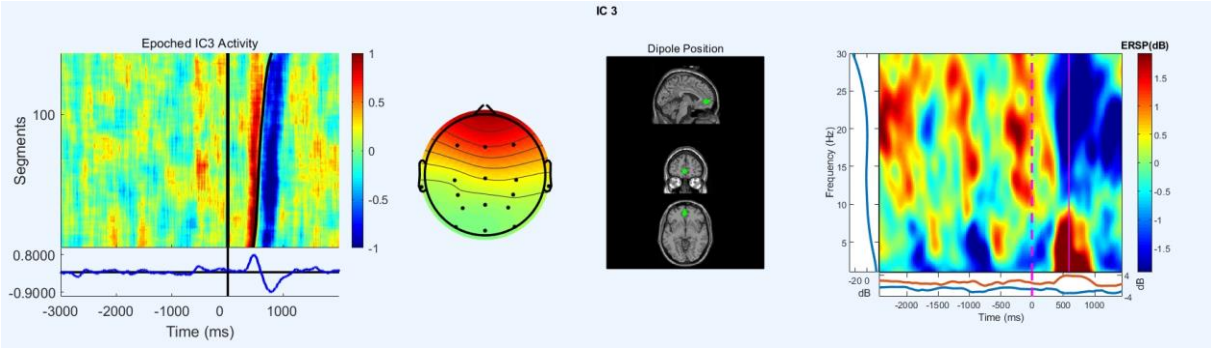
P300 kompleks neuroloških reakcija prema definiciji potaknuti će djelovanje subjekta na detektiranu ciljanu stimulaciju što je vidljivo iz prikaza karakteristika nezavisnih komponenti 2 i 16 na slici 4.3. Obje komponente imaju prostornu distribuciju između frontalne i temporalne regije mozga dok je točna lokacija komponenti u lijevom i desnom dijelu mozga zaduženog za motoričku aktivnost, odnosno kontrolu pokreta. Pošto je subjekt čija su mjerenja prikazana, osoba s dominantnijom desnom rukom koja je ujedno korištena za pritiskanje tipke, lijeva polutka zadužena za upravljanje desnom stranom tijela je aktivnija što je vidljivo iz temporalnog i spektralnog prikaza obje nezavisne komponente. ERSP kod obje nezavisne komponente ukazuje na desinkronizaciju u alfa i beta području za vrijeme aktivnog pritiskanja tipke. Navedena pojava normalna je za neurološke aktivnosti povezane s pokretima tijela gdje je smanjenje amplitude odnosno prigušenje μ-valova obilježje aktivnog upravljanja nekim od ekstremiteta [1], [36], [107], dok je porast energije u istom frekvencijskom području obilježje prestanka motoričkih aktivnosti. Iako su karakteristike nezavisnih komponenti gotovo identične, pretpostavka je da nezavisna komponenta 16 nije posljedica pritiskanja tipke već rezultat nesvjesne motoričke aktivnosti lijeve polovice tijela.

Analiza nezavisnih komponenti EEG mjerenja prikupljenih na drugom subjektu izvršena je identično kao i kod prvog subjekta. Dobivene neurološke aktivnosti raspodijeljene su tako da maksimalno odgovaraju nezavisnim komponentama dobivenih u prethodnoj analizi, te su prikazane na slikama 4.6, 4.7 i 4.8. Iako je neke nezavisne generatore neurološke aktivnosti preko promatranih karakteristika moguće lako klasificirati, određene komponente svojim karakteristikama ne omogućavaju jasnu klasifikaciju i pridruživanje reakcije određenoj grupi neuroloških reakcija (npr. P3f, P3b).

Na slici 4.6 kao prva reakcija na stimulacije istaknuta je nezavisna komponenta 9 čija su promatrana svojstva gotovo identična nezavisnoj komponenti 9 kod prvog subjekta. Isto kao i



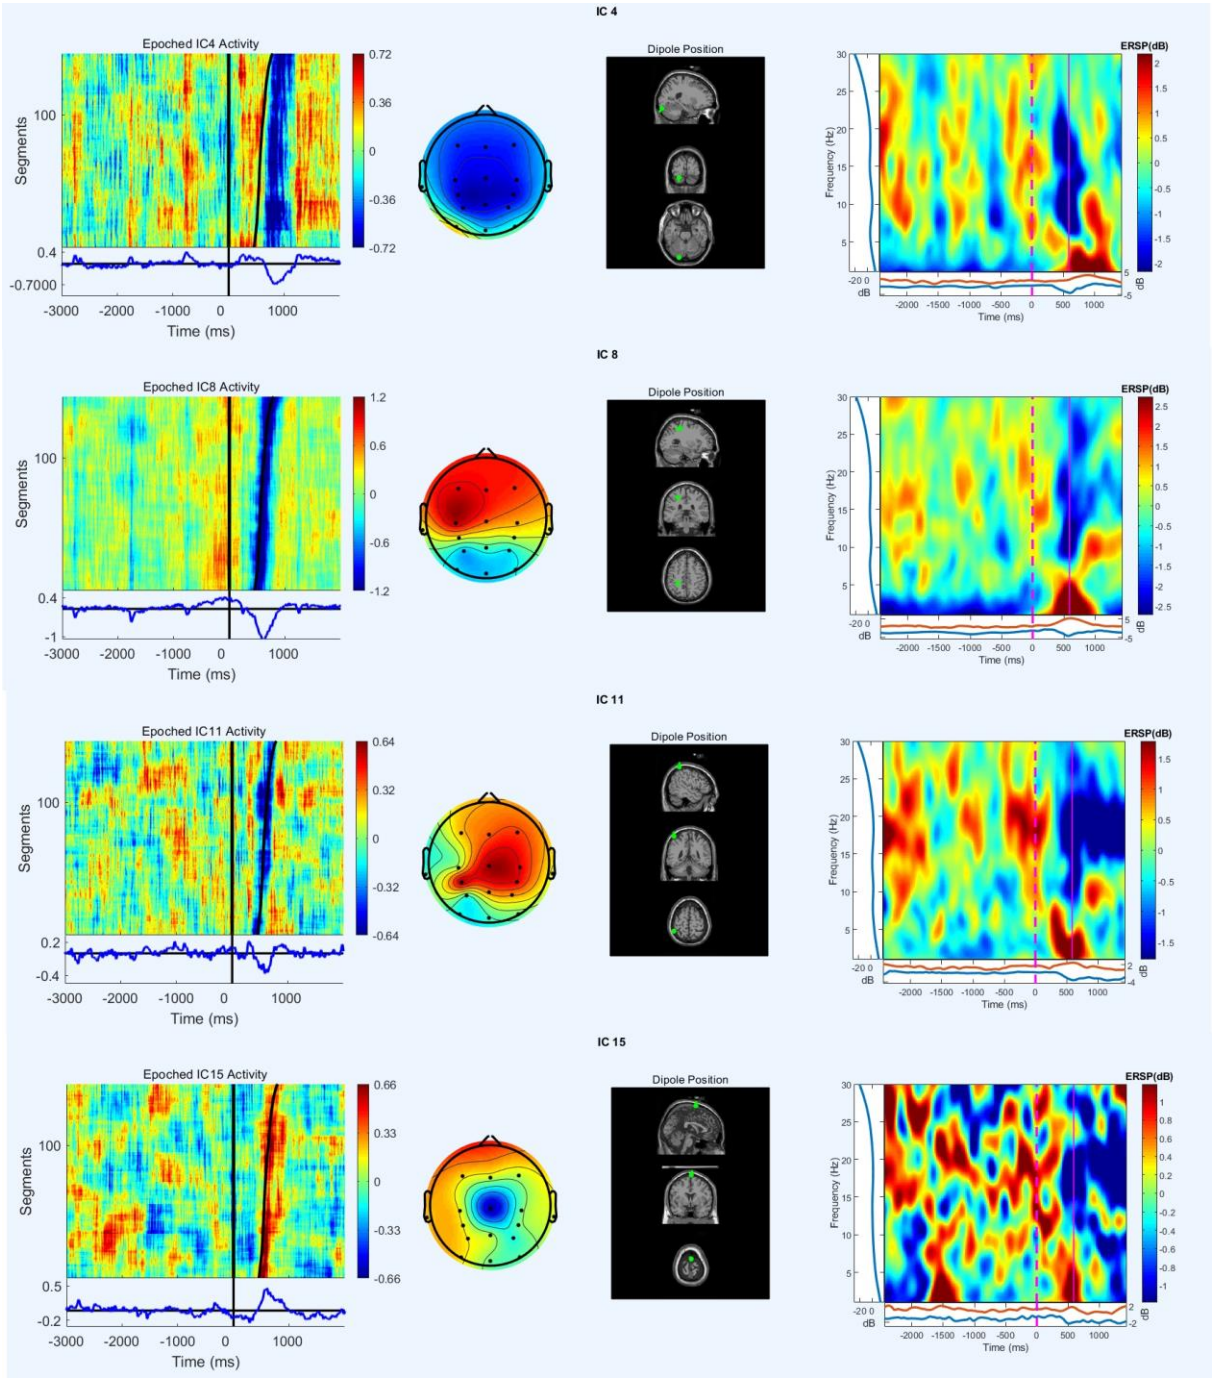
Slika 4.6. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponente neurološke aktivnosti drugog subjekta lokalizirane u temporalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom. Prikazana komponenta zadužena je za obradu akustičnih podražaja.



Slika 4.7. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponente neurološke aktivnosti drugog subjekta lokalizirane u frontalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom.

u prethodnom slučaju reakcija se nalazi u temporalnoj regiji, te ukazuje na obradu i analizu auditornih podražaja, a vremensko-frekvencijska analiza odnosno analiza promjena energije spektra signala ukazuje na gotovo identičnu promjenu spektra ovisno o vremenskim lokacijama ciljanih i ne-ciljanih stimulacija. Za razliku od prethodnih mjerenja kod prvog subjekta u kojima je iz vremenske promjene signala moguće uočiti jasnu razliku između ciljane i ne-ciljane stimulacije, u ovom slučaju vidimo da je reakcija na ne-ciljane stimulacije ponekad jasno razlučiva, a ponekad (stimulacija na -2000 ms) gotovo identična reakciji na ciljanu stimulaciju.

Obrađeni auditorni podražaji prosljeđuju se kao i u prethodnom slučaju u frontalnu regiju, što je vidljivo iz neurološke reakcije prikazane nezavisnom komponentom 3 (slika 4.7), koja po svojoj prostornoj distribuciji podsjeća na nezavisnu komponentu 2 (slika 4.4). Sličnost se



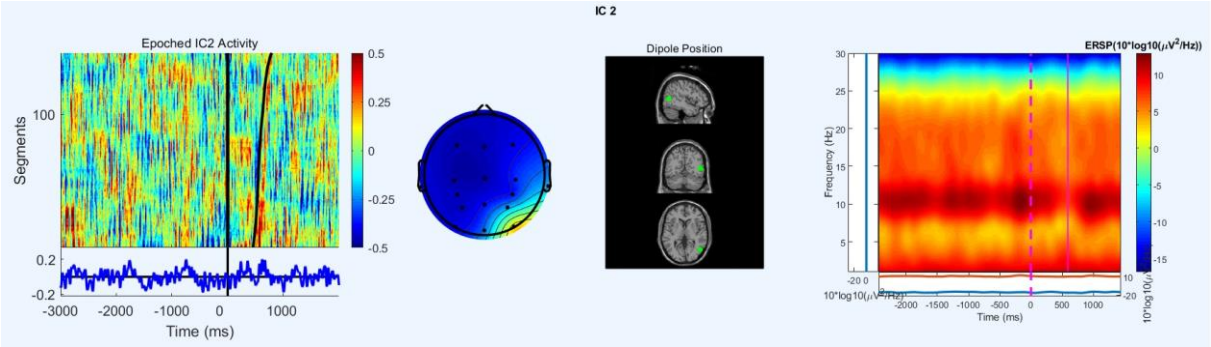
Slika 4.8. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti drugog subjekta lokaliziranih u okcipitalnoj i centalno-parijetalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom. Istaknute komponente na temelju prikazanih karakteristika gotovo sigurno pripadaju P3b odzivu na ciljanu stimulaciju i procesu pritiska tipke.

također može uočiti u porastu energije signala u delta i theta području dok je razlika u nedostatku desinkronizacije u alfa području oko 10-11 Hz. Osim desinkronizacije u beta području oko 19 Hz kao u prethodnom slučaju, jasno je vidljiva desinkronizacija i u višem beta području na frekvencijskom području od 20-30 Hz, što nije bio slučaj s prvim subjektom.

Komponente prikazane na slici 4.8 nezavisne su komponente locirane pretežno u centralno-parietalnoj i okcipitalnoj regiji, a koje nije moguće jednostavno klasificirati ali najvjerojatnije pripadaju neurološkim reakcijama povezanim s P3b komponentama i motoričkim radnjama. Promatrajući nezavisnu komponentu 4 moguće je uočiti kratak skok u amplitudi oko 200 ms nakon ne-ciljane stimulacije dok je kod ciljane stimulacije amplitudni porast izražen sve do pritiska na tipku nakon čega slijedi veliki pad u mjerenom EEG signalu. Analizirajući dobivene karakteristike nezavisne komponente dobiva se dojam da je navedena komponenta dio P3b kompleksa, međutim problem predstavlja područje na kojoj je komponenta locirana, odnosno okcipitalna regija, čija je svrha obrada vizualnih podražaja. Kako u predstavljenoj paradigmi korisnik ima zatvorene oči tijekom eksperimenta, neurološka aktivnost sinkronizirana sa podražajima u navedenoj regiji atipična je aktivnost, koja bi se ipak mogla objasniti korištenjem vizualizacije objekata odnosno stimulacija od strane subjekta, ili netočnom lokalizacijom izvora neurološke aktivnosti zbog već opisanih ograničenja ICA metode. Gotovo identične temporalne i vremensko-frekvencijske karakteristike posjeduje i nezavisna komponenta 8 čija je lokacija ipak u parietalnoj regiji čime bi se ova komponenta mogla lakše povezati sa nezavisnom komponentom 3 kod prvog subjekta, odnosno identificirati kao dio P3b kompleksa. Sličnost u aktivnost između navedenih komponenti u vremensko-frekvencijskoj domeni dodatno bi mogla argumentirati navedeni zaključak.

Nezavisne komponente 11 i 15 prema svojoj prostornoj distribuciji nalaze se oko centralne elektrode u blizini korteksa za upravljanje motoričkim radnjama, čime su ove komponente najvjerojatnije povezane s pritiskom na tipku. Mali porast signala oko 300 ms od ciljane stimulacije mogao bi ukazivati na to da komponenta 11 djelomično pripada i P3b kompleksu. Međutim jaka desinkronizacija signala na alfa i beta području oko 20 Hz prilikom pritiska na tipku kao i kod komponenti 2 i 16 (slika 4.3) ukazuje na to da su većim djelom navedene komponente povezane sa motoričkim kretnjama.

Karakteristična dinamika koja nije direktno povezana sa stimulacijama, te nije uočena kod prvog subjekta prikazana je na slici 4.9, a radi se o prisutnosti alfa valova u okcipitalnoj regiji u situaciji kada korisnik ima zatvorene oči. U toj situaciji kako je već napomenuto, alfa valovi u okcipitalnoj regiji sugeriraju da trenutno nema vizualnih podražaja te da je promatrana regija



Slika 4.9. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponente neurološke aktivnosti drugog subjekta lokalizirane u okcipitalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom. Dobivena komponenta primjer je alfa valova koji u okcipitalnoj regiji nastaju zbog zatvorenih očiju subjekta.

neaktivna. Za razliku od prethodnih komponenti u kojima prikazana promjena spektralne energije, u ovom slučaju kod promatrane nezavisne komponente 2 prikazana je čista vremensko-frekvencijska distribucija dobivena spomenutom Wavelet metodom. Iz vremensko-frekvencijske distribucije lako se može uočiti izraženost frekvencijskog spektra oko 10 Hz u odnosu na ostatak spektra tijekom trajanja cijele epohe.

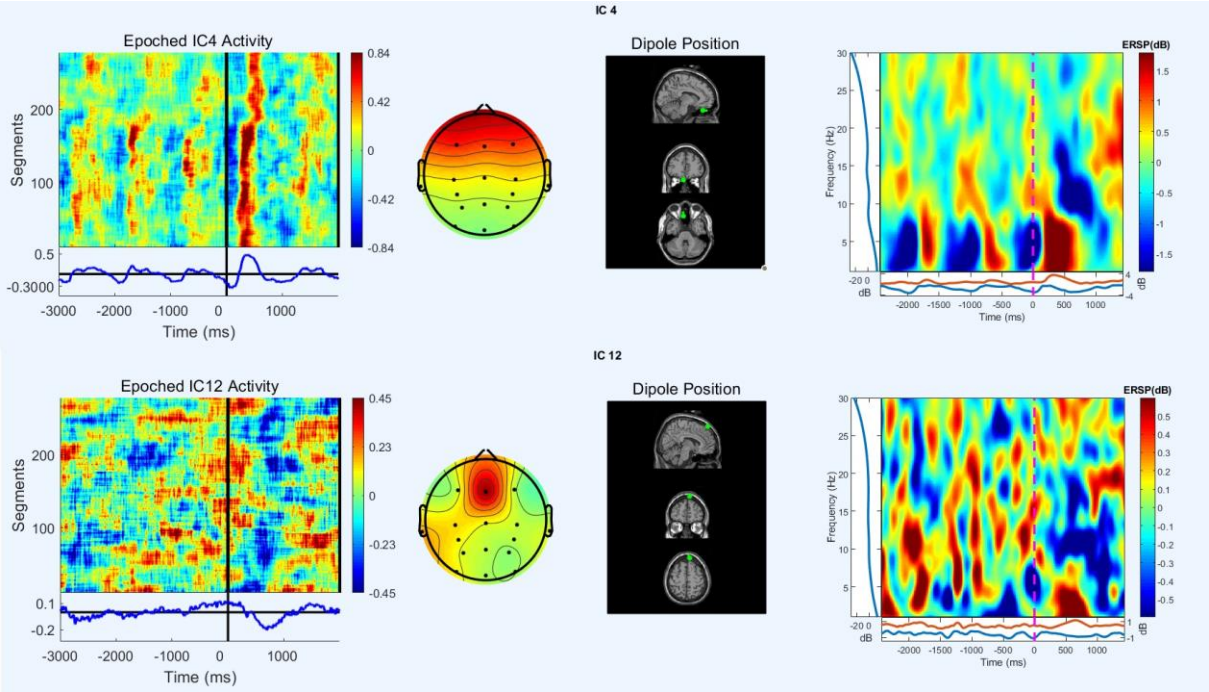
Analizom neuroloških reakcija iz mjerenja prikupljenih kod prvog i drugog subjekata primjenom optimizacijske metode analize nezavisnih komponenti, dobivene su neurološke aktivnosti koje se ponavljaju s ciljanom stimulacijom, čime je ostvaren osnovni preduvjet za klasifikaciju ciljanih i ne-ciljanih stimulacija u predloženoj eksperimentalnoj paradigmi. Dobivene komponente prema izračunatim svojstvima razvrstane su u neurološke reakcije za obradu akustičkih podražaja locirane u temporalnoj regiji, reakcije povezane s P3f grupom komponenti lociranih u frontalnoj regiji, P3b grupom komponenti s prostornom raspodjelom u centralno-parietalnoj regiji, te neurološkim reakcijama povezanim s motoričkim radnjama. Iako se neke od dobivenih komponenti lako i s velikom sigurnošću mogu razvrstati u definirane kategorije neuroloških reakcija, za određeni broj komponenata nije moguće sa sigurnošću definirati njihovo značenje i funkcionalnost. Iz navedenog, vidljivo je da dinamika neuroloških reakcija za istu eksperimentalnu paradigmu odnosno stimulacije može značajno varirati od subjekta do subjekta što će svakako biti jedan od većih izazova u izvedbi BCI sučelja za pisanje.

4.5. Rezultati mjerenja eksperimentalne paradigme bez povratne informacije

Dobiveni rezultati analizom mjerenja u paradigmi s povratnom informacijom prikazani u prethodnom poglavlju sugeriraju da bi se predložena eksperimentalna paradigma mogla koristiti kao osnova za BCI sustav za pisanje. Bitno je istaknuti da u prethodnoj eksperimentalnoj paradigmi s povratnom informacijom, nužna motorička radnja ima pozitivan utjecaj na intenzitet dobivenih komponenti odnosno na samu razlučivost između ciljanih i neciljanih stimulacija. Osim toga navedena motorička aktivnost potpuno je redundantna u sučeljima mozak-računalo (ako je korisnik sposoban pritiskat tipku ili na neki drugi način dati povratnu informaciju prema svojoj okolini tada je koncept prikupljanja, obrade i analize moždane aktivnosti subjekta potpuno redundantan), zbog čega je na subjektima napravljen novi niz eksperimenata u kojima je prilikom registriranja ciljanog podražaja potrebna samo mentalna reakcija subjekta bez fizičkih pokreta. Kao i u prethodnoj paradigmi uz zatvorene oči tijekom aktivne faze eksperimenta zadatak subjekata je napisati relativno kratke riječi (3-6 slova).

Obrada prikupljenih podataka izvršena je identično kao i u prethodnom poglavlju, dok je grafički prikaz karakteristika dobivenih analizom nezavisnih komponenti različit samo u vremenskoj distribuciji promatranog signala. Razlog tome leži u činjenici da su u prethodnom slučaju epohe bile sortirane prema brzini reakcije subjekta na registrirani ciljani podražaj, dok je u ovom slučaju nedostatak povratne informacije uvjetovao raspored epoha prema kronološkom redoslijedu EEG mjerenja. Analizom nezavisnih komponenti dobiveno je nekoliko komponenti koje bi mogle biti povezane s obradom auditornih podražaja kakav je slučaj bio sa nezavisnim komponentama 9 kod prvog i drugog subjekta, međutim u dobivenim neurološkim reakcijama nema jasnih razlika između ciljanih i ne ciljanih stimulacija zbog čega svojstva dobivenih komponenti nisu prikazana.

Promatrajući dobivene nezavisne komponente na slici 4.10 koje su locirane u frontalnoj regiji mozga vidimo da su promatrana svojstva komponenti identična nezavisnim komponentama 1 i 15 kod prvog subjekta u paradigmi s povratnom informacijom prikazanima na slici 4.4. To se posebno odnosi na prostornu distribuciju gdje navedene komponente dijele gotovo identičnu projekciju na skalp, kao i 3D poziciju dobivenu upotrebom DIPFIT metode, zbog čega je moguće direktno povezati nezavisne komponente 1 i 4, te 15 i 12 kao ekvivalentne generatore neurološke aktivnosti. Dodatan argument u takvom grupiranju nezavisnih kompoenenti 1 i 4 svakako je gotovo identična vremensko-frekvencijska distribucija komponenti s izraženom sinkronizacijom u theta valnom području oko 400ms nakon ciljane

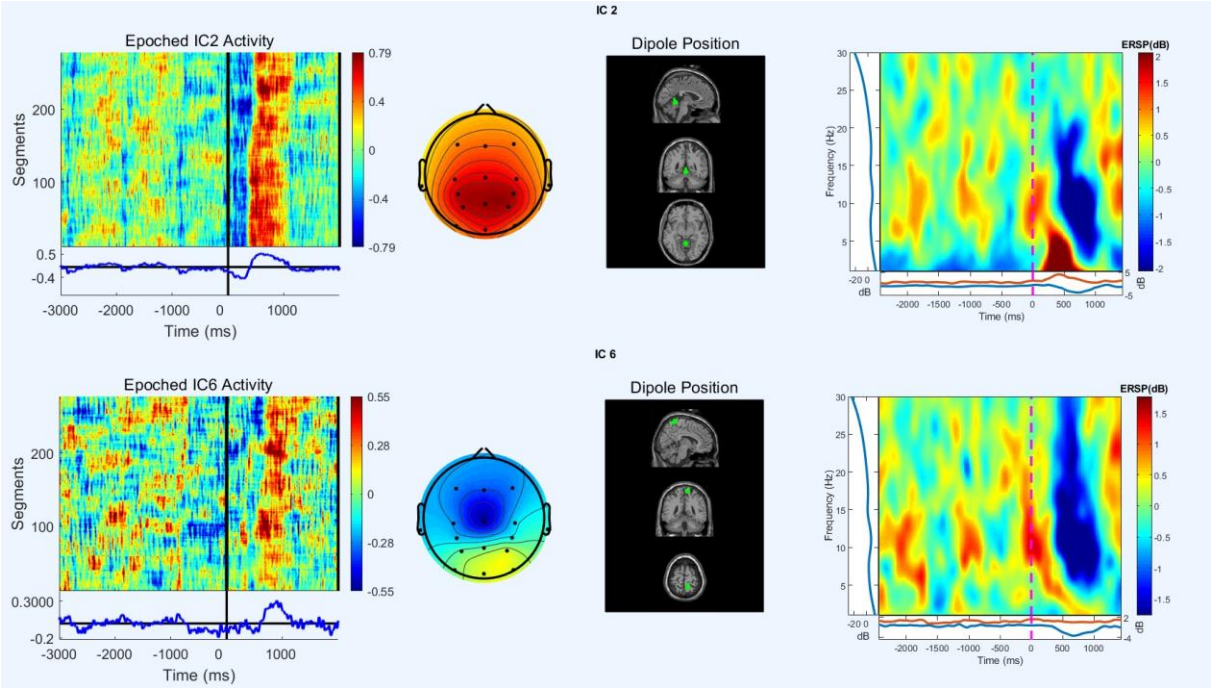


Slika 4.10. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti prvog subjekta lokaliziranih u frontalnoj regiji mozga primjenom predložene eksperimentalne paradigme bez povratne veze.

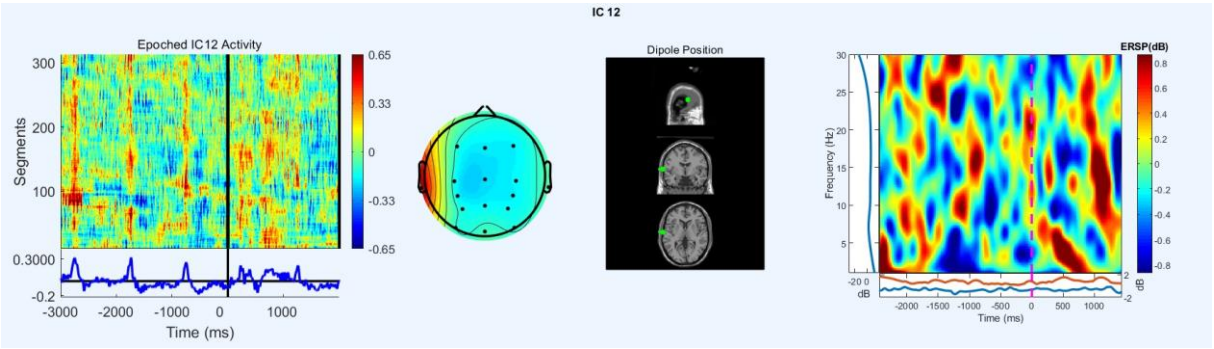
stimulacije, te izražena desinkronizacija u alfa valnom području, s gotovo identičnim vremenskim kašnjenjem za stimulacijom kao i kod slučaja sinkronizacije.

Osim spomenutih nezavisnih komponenti smještenih u frontalnoj regiji mozga, iz analize nezavisnih komponenti moguće je izdvojiti još dvije nezavisne komponente s lokacijom u parietalnoj regiji mozga prikazane na slici 4.11. Komponente je po prikazanim svojstvima moguće povezati s komponentama 3 i 6 dobivenih u eksperimentalnoj paradigmi s povratnom informacijom (slika 4.8), a koje predstavljaju generatore P300 kompleksa. Analizom neuroloških reakcija kod prvog subjekta vidljivo je da se u obje eksperimentalne paradgime kod korisnika javljaju karakteristični generatori neurološke aktivnosti povezani s P3b kompleksom, a čija svojstva jasno ukazuju na razliku između ciljanih i ne-ciljanih stimualcija. Upravo navedena razlika u neurloškim aktivnostima kod paradigme bez povratne informacije temeljno je svojstvo koje je korišteno za klasifikaciju ciljanih i ne-ciljanih slova.

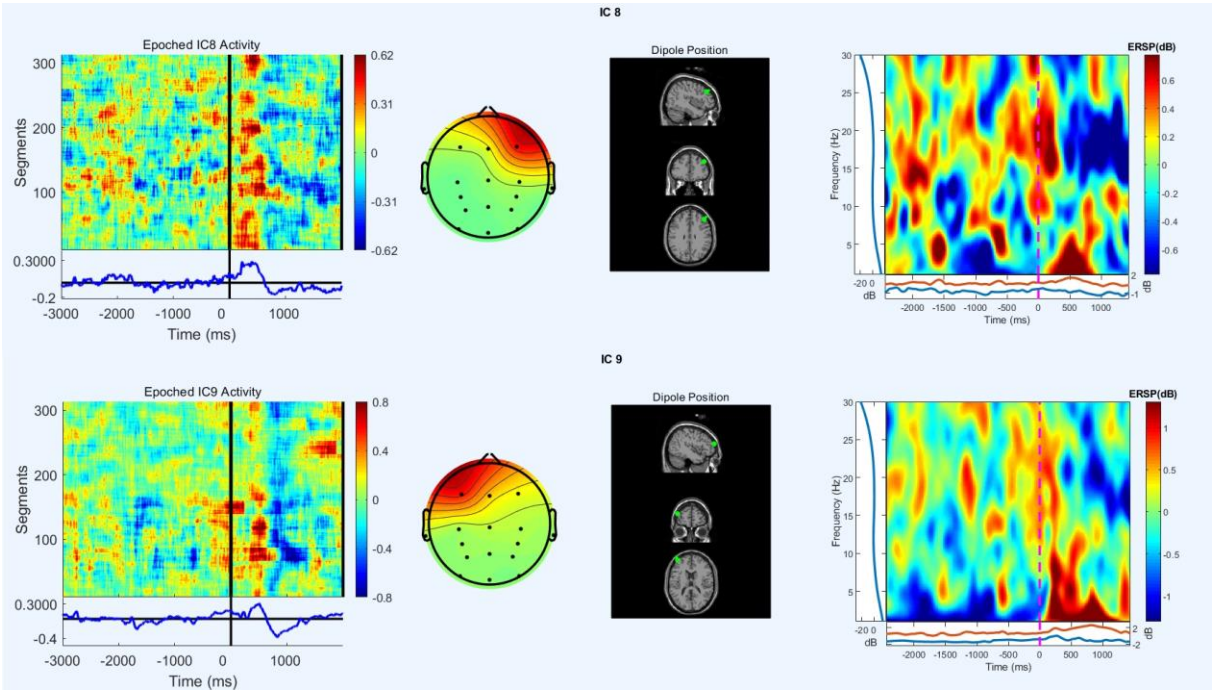
Rezultati analize nezavisnih komponenti za eksperimentalnu paradigmu bez povratne informacije kod drugog subjekta prikazani su na slikama 4.12 do 4.14. Za razliku od prvog subjekta gdje analiza nezavisnih komponenti na eksperimentalnoj paradigmi bez povratne informacije nije izdvojila neurološku aktivnost povezanu sa obradom zvučnih podražaja u



Slika 4.11. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti prvog subjekta lokaliziranih u parijetalnoj regiji mozga primjenom predložene eksperimentalne paradigme bez povratne veze. Istaknute komponente na temelju prikazanih karakteristika gotovo sigurno pripadaju P3b odzivu na ciljanu stimulaciju.



Slika 4.12. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponente neurološke aktivnosti drugog subjekta lokaliziraih u temporalnoj regiji mozga primjenom predložene eksperimentalne paradigme bez povrate veze. Prikazana komponenta zadužena je za detekciju i obradu akustičnih podražaja.

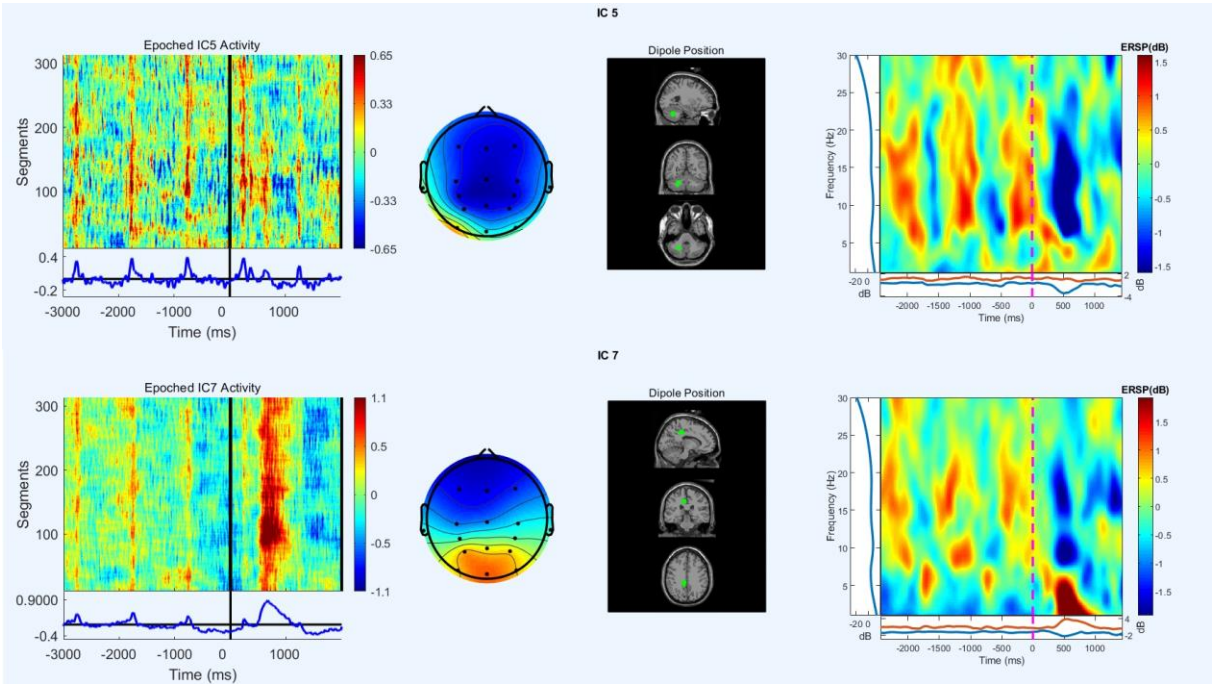


Slika 4.13. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti drugog subjekta lokaliziranih u frontalnoj regiji mozga primjenom predložene eksperimentalne paradigme bez povrate veze.

temporalnoj regiji, kod drugog subjekta analizom je dobivena nezavisna komponenta 12, čija se svojstva uvelike poklapaju sa komponentom broj 9 prikazanoj na slici 4.6. Iz vremenskog prikaza signala neurološke aktivnosti jasno je vidljiva razlika u usrednjenim reakcijama drugog subjekta na ciljane i ne-ciljane stimulacije. Promatrajući ne-ciljane stimulacije, vidljiv je brz porast, ali i smanjenje amplitude oko 200 ms nakon stimulacije, dok kod ciljanih stimulacija neurološka reakcija aktivna kroz cijelu epohu (1 sekunda).

Kao i u eksperimentalnoj paradigmi s povratnom informacijom analiza zvučnog podražaja uzrokovat će aktivnosti u frontalnoj regiji prikazanu na slici 4.13. U ovom slučaju analiza nezavisnih komponenti rezultirala je s dvije odvojene komponente koje su vjerojatno posljedica jedinstvene neurološke reakcije uzrokovane ciljanom stimulacijom kao i u prethodnoj paradigmi čija je aktivnost u frontalnoj regiji određena nezavisnom komponentom 3 prikazanoj na slici 4.7. Gotovo identična temporalna i vremensko-frekvencijska svojstva kao i simetrična lokalizacija s obzirom na lijevu i desnu polutku dodatni su argumenti koji potvrđuju da je dobivena neurološka aktivnost povezana s frontalnim neurološkom aktivnosti dobivena kod obje eksperimentalne paradigme.

Preostale nezavisne komponente povezane su s parietalnom i okcipitalnom regijom mozga,



Slika 4.14. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti drugog subjekta lokaliziranih u okcipitalnoj i parijetalnoj regiji mozga primjenom predložene eksperimentalne paradigme bez povrate veze.

odnosno s P3b kompleksom neuroloških reakcija, a prikazane su na slici 4.14. Dobivena nezavisna komponenta 5 pojavljuje se u okcipitalnoj regiji, međutim sličnost dinamike navedene komponente s dinamikom nezavisne komponente 12 u temporalnoj regiji ostavlja mogućnost da su analizom nezavisnih komponenti dobivene dvije nezavisne komponente kao projekcije jedinstvenog neurološkog procesa obrade akustičnih podražaja definiranog nezavisnom komponentom 9 iz prethodne paradigme (slika 4.6). Posljednja nezavisna komponenta 7, može se usporediti s nezavisnom komponentom 3 (slika 4.5) u paradigmi s povratnom informacijom i nezavisnom komponentnom 2 (slika 4.10) u paradigmi bez povratne informacije kod prvog subjekta, a koje smo već klasificirali kao elemente P300b reakcije. Sve promatrane komponente imaju gotovo identičnu lokaciju u parietalnoj regiji mozga, te je za sve komponente karakterističan pozitivan porast amplitude signala oko 300 ms do 500 ms od početka stimulacije što i jesu glavne odlike P3b generatora moždane aktivnosti. Također, promatrajući vremensko-frekvencijsku distribuciju signala, odnosno promjenu spektralne energije signala vidljive su sličnosti s istoznačnim komponentama kod drugih subjekata, gdje je moguće uočiti karakterističnu sinkronizaciju na niskim frekvencijama u području delta i theta valova, te desinkronizaciju u alfa i niskom beta području do 15 Hz.

Usporedbom rezultata nezavisnih komponenti neuroloških reakcija u eksperimentalnoj paradigmi s povratnom informacijom s rezultatima neuroloških reakcija u eksperimentalnoj paradigmi bez povratne informacije vidljiva je jasna razlika u količini i intenzitetu neuroloških reakcija koje je moguće dobiti primjenom obje vrste eksperimenta. Tako je u slučaju eksperimentalne paradigme s povratnom informacijom, pritiskanje tipke osiguralo dodatan skup nezavisnih neuroloških reakcija, povezanih isključivo s navedenom radnjom, kao i povećalo intenzitet ostalih neuroloških reakcija povezanih s P300 kompleksom. Uz već prethodno spomenutu varijabilnost nezavisnih izvora neuroloških reakcija između subjekata, navedeno smanjenje intenziteta neuroloških reakcija povezanih s P300 odzivom, dodatno će otežati klasifikaciju ciljanih i ne-ciljanih stimulacija.

5. Sučelje mozak-računalo za pisanje – validacija sustava

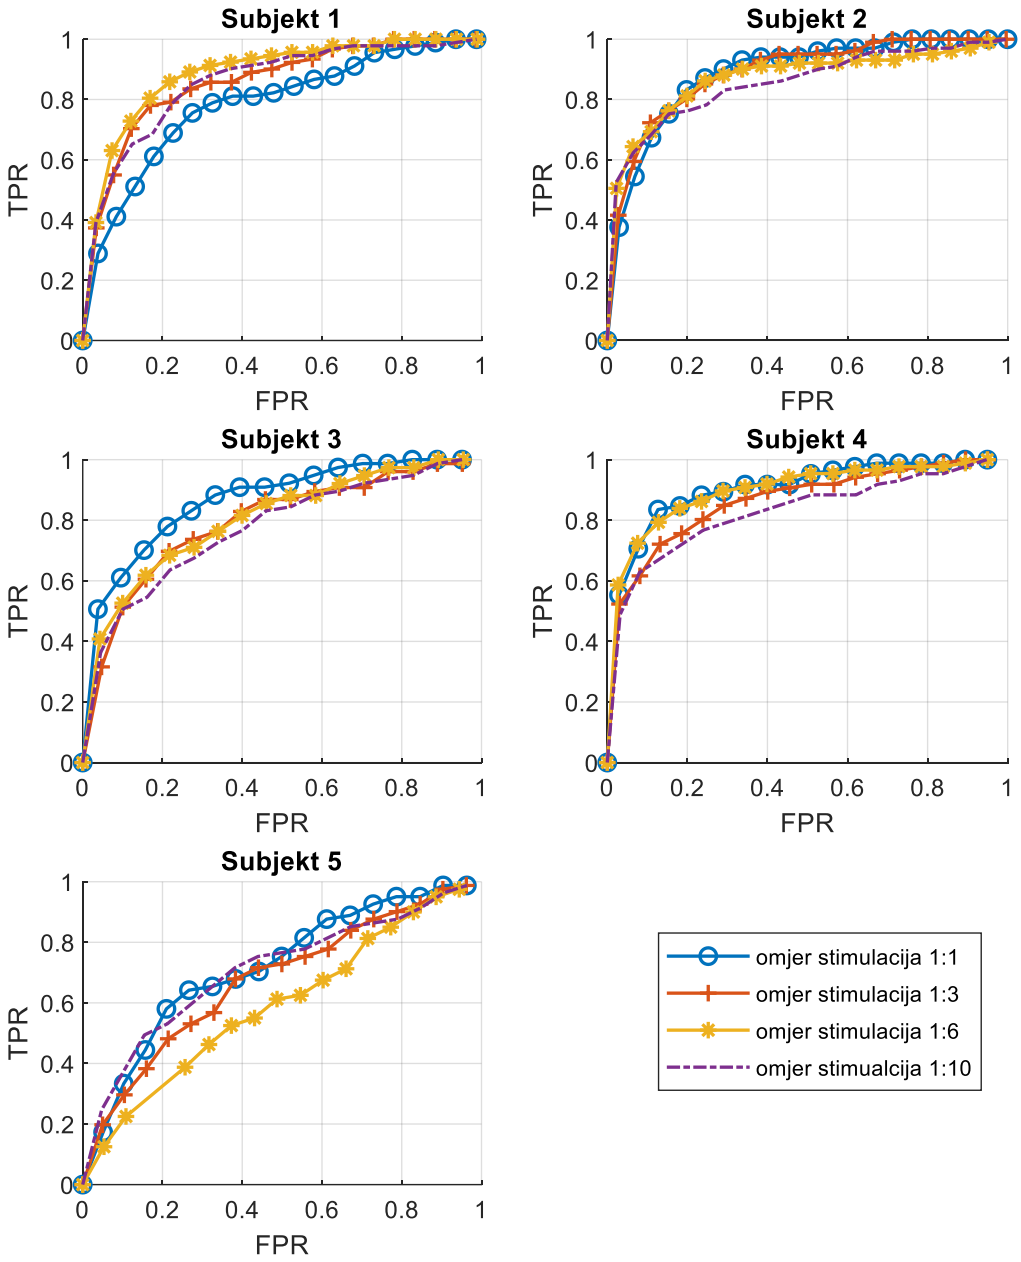
5.1. Rezultati treniranja klasifikatora

Sljedeći korak u projektiranju sučelja mozak-računalo treniranje je klasifikatora opisanih u poglavlju 3.3, čija je glavna zadaća odgovoriti na pitanje radi li se o ciljanoj ili ne-ciljanoj stimulaciji na temelju prikupljenih EEG podataka. Analiza mjerenja neurološke aktivnosti dobivenih korištenjem predložene eksperimentalne paradigme opisana u prethodnim poglavljima pokazala je kod prvog i drugog jasne razlike u dinamici reakcija na ciljanu i ne-ciljanu stimulaciju, zbog čega će se podatci prikazani u poglavlju 4.5 koristiti za učenje predloženih klasifikatora.

5.1.1. xDAWN + SVM

Prvi korak u treniranju SVM klasifikatora je određivanje koeficijenata *xDAWN* prostornog filtera, čijom će se primjenom na EEG signal kako je opisano u prethodnom poglavlju istaknuti komponente povezane sa P300 kompleksom neuroloških reakcija. U tu svrhu obrađeni segmenti poslagani su u jedinstvenu matricu, odnosno definirana je Toeplitz matrica s jedinicama u trenutcima početnog djelovanja ciljane stimulacije, te je na temelju *xDAWN* algoritma [78] za svakog subjekta zasebno izračunat prostorni filter $U \in R^{16x16}$. Na temelju karakterističnih vrijednosti za sve subjekte odabrana su N_f najdominantnija vektora na koje će se projicirati više od 95% energija originalnog EEG signala. Primjenom prostornog filtera na pred obrađenim EEG signalima odnosno segmentima, dobivamo $2 \leq N_f \leq 3$ vremenska vektora koji predstavljaju istaknute P300 komponente na cijelom segmentu. Dobivene komponente naknadno su rastavljene u epohe tako da je nakon svake stimulacije izdvojen dio uzoraka komponenti u trajanju od jedne sekunde (svaki segment sastoji se od 22 stimulacije odnosno epohe). Dodatno pojednostavljenje pri učenju SVM klasifikatora ostvareno je pomoću poduzorkovanja epoha sa faktorom 4, gdje je sada svaka epoha definirana sa 128 uzoraka.

Dobivene epohe služe kao podatkovni ulaz u SVM klasifikator, dok je na drugi ulaz potrebno dovesti informaciju o klasi stimulacije koju navedena epoha predstavlja. Pošto se radi o jednostavnoj binarnoj klasifikaciji svaka je epoha određena s 0 ako se radi o ne-ciljanoj ili 1 ako se radi o ciljanoj epohi. Učenje SVM klasifikatora implementirano je s više različitih



Slika 5.1. Rezultati treniranja i validacije klasifikacije ciljanih i ne-ciljanih stimulacija primjenom *xDAWN* prostornog filtera i SVM klasifikatora na pred-obrađenim EEG podatcima prikupljenih predloženom eksperimentalnom paradigmom bez povratne veze.

omjera ciljanih i ne-ciljanih epoha, i to u omjerima 1:1, 1:3, 1:6 i 1:10. U tu svrhu napisana programska podrška koja u prvoj iteraciji nasumično odabire 70% segmenata za treniranje SVM klasifikatora dok je preostalih 30% predviđen za validaciju naučenog klasifikatora. Iz skupa podataka za treniranje SVM klasifikatora programska podrška u sljedećem koraku iz svakog segmenta odabire ciljanu epohu i jednu ili više ne-ciljanih epoha ovisno o odabranom omjeru. Set podataka za validaciju nije reduciran, tako da je validacija klasifikacije neuronske mreže izvršena na cjelokupnom setu. Izvedba, treniranje i validacija SVM klasifikatora odrađena je u MATLAB programskom okruženju.

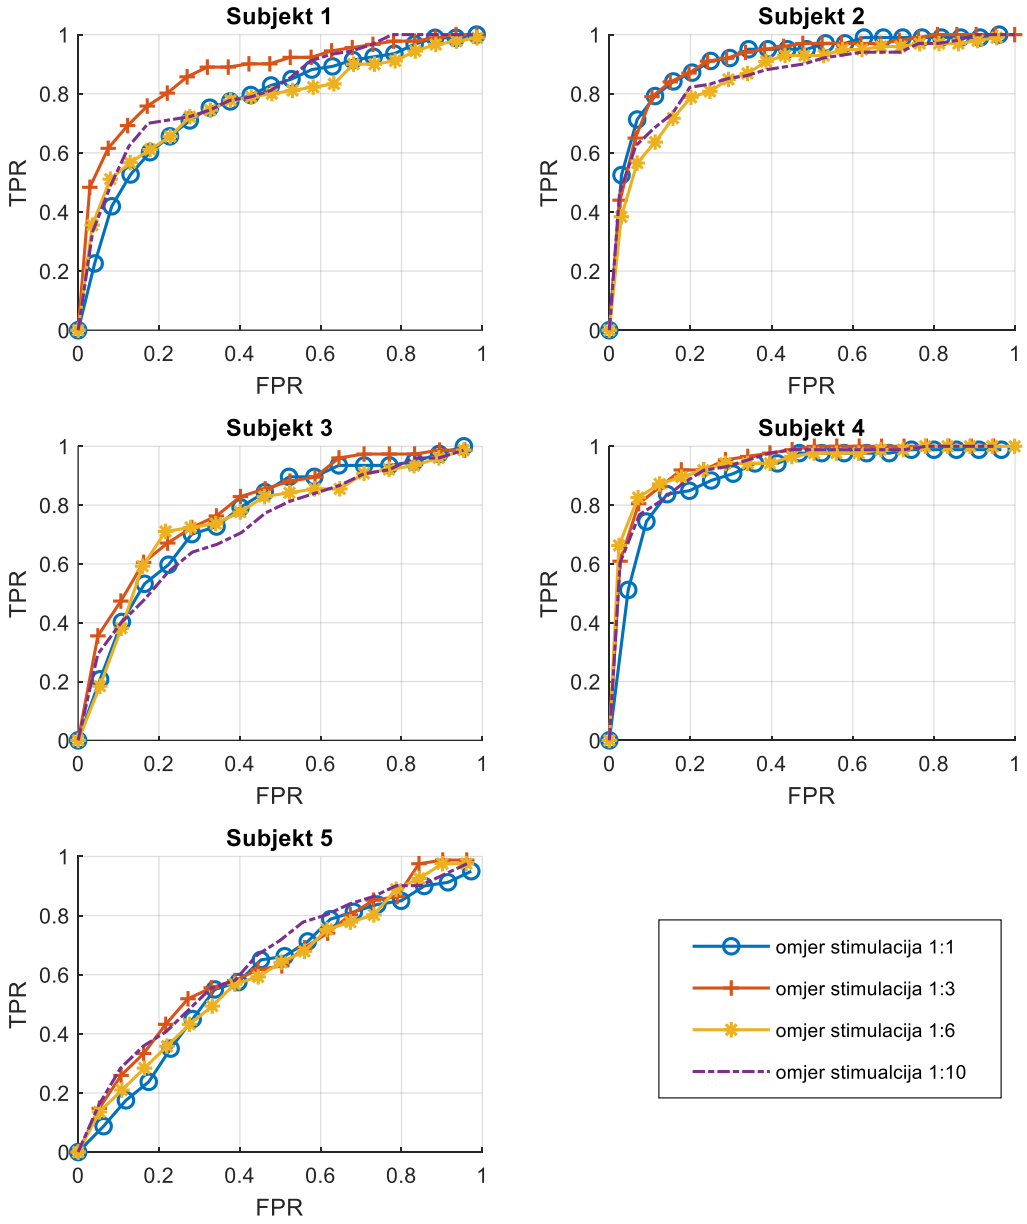
Rezultati validacije SVM klasifikatora za različite omjere ciljanih i ne-ciljanih stimulacija prikazani su na slici 5.1. u obliku ROC krivulja. Na x-osi ROC krivulje nalazi se omjer netočno klasificiranih ciljanih stimulacija (engl. *false positive rate*, FPR) dok se na y-osi nalazi omjer točno klasificiranih ciljanih stimulacija (engl. *true positive rate,* TPR), dok sama krivulja predstavlja odnos točno i netočno klasificiranih ciljanih stimulacija za različite pragove klasifikacije (razine pouzdanosti klasifikacije prema kojima se određuje radi li se o ciljanoj ili ne-ciljanoj stimulaciji). U slučaju idealnog klasifikatora koji s 100% sigurnosti može raspoznati ciljane i ne-ciljane stimulacije idealnu ROC krivulju moguće je opisati s dvije duljine opisane točkama (0, 0) i (1,0) i točkama (1,0) i (1,1). Za takav klasifikator mjera uspješnosti klasifikacije koja se određuje kao površina ispod ROC krivulje (engl. *area under curve*, AUC) je maksimalna i iznosi 1.

Rezultati na slici 5.1. pokazuju izvrsne klasfikacijske rezultate kod drugog i četvrtog subjekta koji malo variraju s omjerom ciljanih i ne-ciljanih epoha. Navedena tvrdnja dodatno je potvrđena i površinom ispod krivulja koja u najboljem slučaju iznosi 0.89 za drugog subjekta odnosno 0.905 za četvrtog subjekta. Nešto slabiji ali zadovoljavajući rezultati primjetni su i kod prvog i trećeg subjekta gdje prvi subjekt ima osjetniju razliku između učenja klasifikatora s različitim omjerima ciljanih i ne-ciljanih epoha. Maksimalni iznos površine ispod ROC krivulje za omjer 1:6 iznosi 0.85 za prvog subjekta i 0.81 za trećeg subjekt što dodatno ukazuje na uspješnost treniranja SVM klasifikatora kod navedenih subjekata. ROC krivulja petog subjekta ima tendenciju prema najgoroj mogućoj situaciji u kojoj klasifikator ima 50-50% mogućnosti da točno detektira ciljanu stimulacija, a koja je opisana duljinom definiranom točkama (0,0) i (1,1).

5.1.2. Konvolucijska neuronska mreža

Za razliku od prethodnog primjera, treniranje konvolucijske neuronske mreže izvršeno je s originalnim pred-obrađenim EEG signalima, bez dodatnog prostornog filtriranja signala. Prethodno obrađeni segmenti rastavljeni su u epohe duljine jedne sekunde, čime je svaki segment rastavljen u 22 epohe od kojih je jedna ciljana epoha, odnosno epoha u kojoj se nalazi reakcija na ciljanu stimulaciju. Sve navedene epohe nadalje su pod-uzorkovane s faktorom 4 tako da je svaka epoha sadrži 128 vremenska uzoraka. Dobivene epohe služe kao podatkovni ulaz u neuronsku mrežu, dok je na drugi ulaz kao i slučaju SVM klasifikatora potrebno dovesti informaciju o tipu stimulacije koju epoha predstavlja, gdje su s nula označene epohe s ne-ciljanom stimulacijom, a s jedan epohe s ciljanim podražajima. Konvolucijska neuronska mreža učena je s istim vrijednostima parametara kao i SVM, konkretnije 70% segmenata je uzeto za treniranje, a ostatak za validaciju, a treniranje mreže izvršeno je s istim omjerima ciljane i ne-ciljanje stimulacije: 1:1, 1:3, 1:6, 1:10. Set podataka za validaciju nije reduciran s predloženim omjerima. Neuronska mreža definirana je prema predloženoj EEGNet strukturi gdje je prvi konvolucijski sloj određen s deset temporalnih filtera ($F_1 = 10$) i četiri prostorna filtera ($D = 4$), a modeliranje i treniranje mreže izvedeno je u MATLAB programskom okruženju. Za treniranje klasifikatora odabran je ADAM optimizator, dok je za uspješno učenje mreže broj ponavljanja podataka postavljen na 10 – 30 iteracija ovisno o ukupnom broju podataka tj. omjeru ciljanih i ne-ciljanih stimulacija.

Rezultati validacije naučene konvolucijske neuronske mreže za sve subjekte ponovo su prikazani u obliku ROC krivulja na slici 5.2. Dobiveni rezultati gotovo su identični rezultatima dobivenim primjenom *xDAWN* filtera i SVM klasifikatora, gdje su najbolji rezultati opet ostvareni kod drugog i četvrtog subjekta, s maksimalnom površinom ispod krivulje za omjer ciljanih i ne-ciljanih stimulacija 1:3 u iznosu od 0.91 odnosno 0.94. Ostvareni rezultati kod navedenih subjekata nešto su bolji i od SVM klasifikacije, te sugeriraju da bi kod navedena dva subjekta trebali imati vrlo dobru primjenu navedenog sučelja. Kod prvog subjekta u odnosu na ostale krivulje istaknuta je ROC krivulja s omjerom ciljane i ne-ciljane stimulacije 1:3, te površina ispod navedene krivulje iznosi 0.87. Povrh toga, vrlo dobri rezultati ostvareni su CNN klasifikatorom s istim 1:3 omjerom stimulacija kod trećeg subjekta gdje je ostvarena površina 0.80, što je gotovo identičan rezultat kao i kod SVM klasifikatora. Kod petog subjekta ostvareni su nešto lošiji rezultati nego u prethodnoj validaciji, međutim vrlo vjerojatno kod oba klasifikatora dobivena točnost neće biti dovoljna za praktično korištenje predloženog sučelja za pisanje.



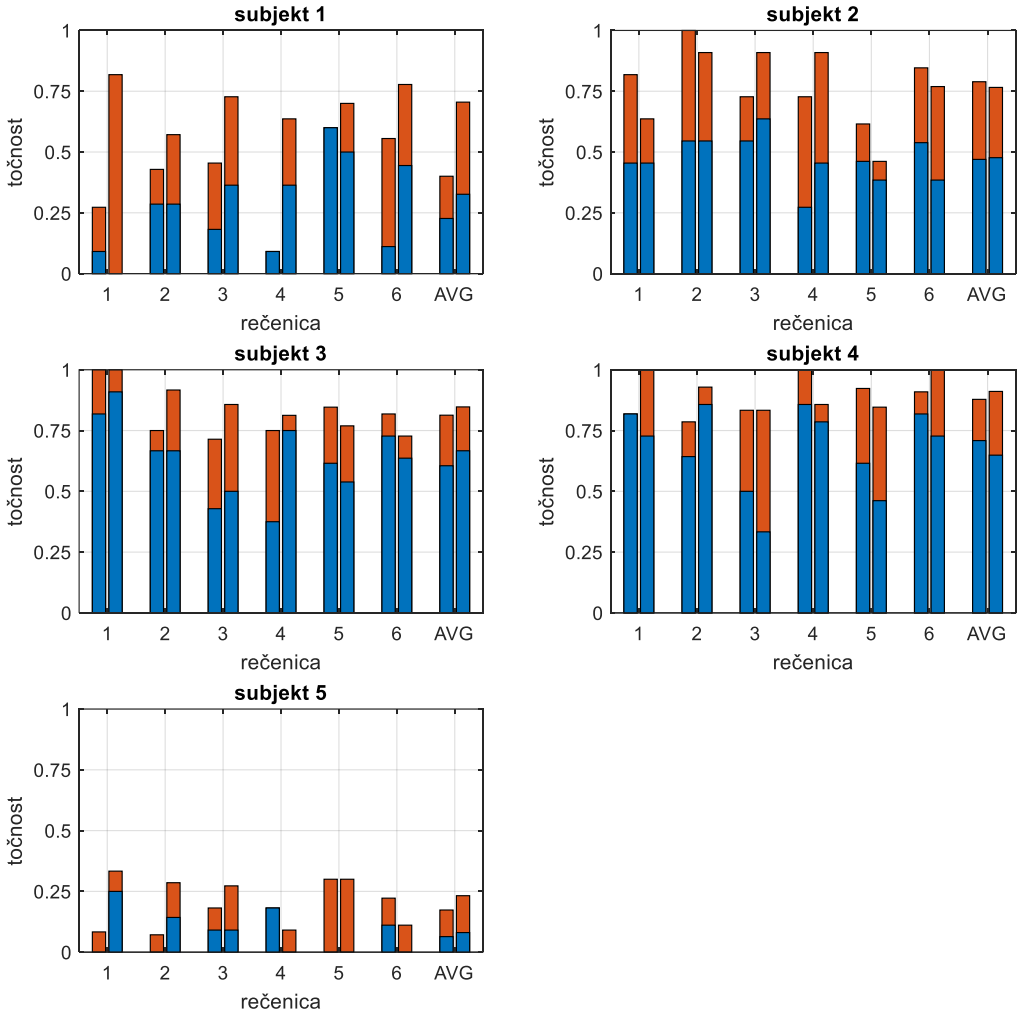
Slika 5.2. Rezultati treniranja i validacije klasifikacije ciljanih i ne-ciljanih stimulacija primjenom konvolucijske neuronske mreže na pred-obrađenim EEG podatcima prikupljenih primjenom predložene eksperimentalne paradigme bez povratne veze.

5.2. Rezultati validacije sučelja mozak-računalo za pisanje

Implementacijom klasifikatora kompletiran je posljednji dio sučelja mozak-računalo za pisanje primjenom auditornih podražaja, te je u sljedećem koraku potrebno dodatno ispitati predloženu eksperimentalnu paradigmu. Sa svih pet prethodno mjerenih subjekata napravljena su nova mjerenja u kojima je cilj korištenjem sustava napisati tri kratke i jednostavne rečenice „ZOVEM SE xxx“, „MISLI SE VIDE“, „OSJECAM SE DOBRO“ , gdje su subjekti svaku rečenicu napisali dva puta u dvije različite sesije. Pojednostavljenost sustava onemogućuje unos razmaka između riječi, zbog čega je svakom subjektu napomenuto da je fokus potrebno usmjeriti samo na slova unutar rečenica.

Kao i sa prethodnim mjerenjima, sva novo prikupljena EEG mjerenja pred-obrađena su na način opisan u poglavlju 4.3 s razlikom da je i u ovom slučaju kao i kod učenja klasifikatora svakoj stimulaciji odnosno slovu pridijeljena jedinstvena epoha u trajanju od jedne sekunde koja je pod-uzorkovana na 128 uzorka. Prema navedenom, za svaki segment mjerenja, odnosno od strane korisnika napisano slovo rečenice, potrebno je klasificirati niz od 22 stimulacije, te ne temelju dobivenih klasifikacijskih rezultata odabrati onu stimulaciju s maksimalnom vjerojatnošću da se radi o ciljanom slovu. Oba prethodno opisana klasifikatora korištena su za identificiranje ciljanog slova, a rezultati točnosti sustava kod svih pet subjekata na svih šest mjerenja prikazani su na slici 5.3. Na y-osi prikazana je konačna točnost sustava, a na x-osi nalazi se redni broj mjerenja odnosno napisane rečenice, dok zadnji element na navedenoj osi predstavlja usrednjenu točnost kroz svih 6 mjerenja. Točnost svake rečenice prikazana je s dva stupca gdje se prvi odnosi na primjenu *xDAWN* filtera i SVM klasifikator, a drugi stupac na CNN klasifikator. Veličine definirane plavom bojom prikazuju konačnu točnost sustava koji tražene ciljane stimulacije odabire na temelju maksimalne klasifikacijske vrijednosti iz niza od 22 slova. U slučaju SVM klasifikatora dobivena klasifikacijska vrijednost predstavlja udaljenost od vektorima potpomognute ravnine koja razdvaja dvije klase subjekata, dok u slučaju neuronske mreže dobivena vrijednost između 0 i 1 predstavlja vjerojatnost s kojom je mreža sigurna da se radi o ciljanoj (1) ili ne-ciljanoj (0) stimulaciji.

Sa slike 5.3. vidljivo je da je treći subjekt ostvario najbolju točnost u iznosu 91% pri pisanju prve rečenice primjenom CNN klasifikatora. Daljnjim korištenjem sustava vidljive su oscilacije u točnosti sustava, međutim u svim rečenicama konačna točnost sustava kreće se između vrlo dobrih 50% i 75%. Veoma slični, ali ipak nešto slabiji rezultati ostvareni su primjenom SVM metode, pa je tako u prvoj rečenici dobivena točnost od 81%, dok je jedina značajnija razlika u klasifikacijskim metodama ostvarena u četvrtoj rečenici, gdje je točnost dobivena CNN



Slika 5.3. Rezultati pisanja šest rečenica primjenom predloženog sučelja mozak – računalo uz primjenu xDAWN/SVM klasifikacije (lijevi stupac unutar svake rečenice) i konvolucijske neuronske mreže (desni stupac unutar istih rečenica). AVG predstavlja ostvarenu srednju vrijednost točnosti svih šest rečenica. Plavim stupcima označena je točnost sustava, ako je ciljana stimulacija odabrana na temelju maksimalne klasifikacijske vrijednosti. Crvenim stupcima definirana je vjerojatnost da se ciljana stimulacija nalazi unutar skupa od pet stimulacija sa najboljima klasifikacijskim vrijednostima.

klasifikatorom oko 32% bolja u odnosnu na SVM. Prosječna točnost ostvarena SVM klasifikatorom iznosi 60%, dok je u slučaju CNN klasifikatora dobivena nešto veća točnost te iznosi oko 67%. Ostvarene točnosti kod četvrtog subjekta ukazuju na to da je u slučaju navedenog subjekta SVM nešto bolja metoda koja u prosjeku daje 5% bolje rezultate; 71% naspram 66% koliko je ostvareno pomoću neuronske mreže. Primjenom SVM klasifikatora dobivene su točnosti koje variraju između 50% i 85%, dok je točnost prilikom CNN klasifikatora između 50% i 75%, s iznimkom treće rečenice u kojoj je ostvarena točnost od tek 33%.

Iako je validacija treniranja oba tipa klasifikatora za prvog i drugog subjekta pokazala vrlo dobre i odlične rezultate, pogotovo kod drugog subjekta, rezultati točnosti pisanja rečenica uporabnom predloženog sučelja nisu dostigli predviđenu razinu. Kod drugog subjekta oba klasifikatora su ostvarila gotovo identičnu prosječnu vrijednost od 50%, dok je za SVM klasifikator točnost varirala između 30-50%, a za CNN klasifikator između 40-65%. Još lošija situacija je kod prvog subjekta, gdje je primjenom neuronske mreže u pet od šest rečenica ostvarena točnost između 30-50%, dok je primjenom SVM klasifikatora u većini slučajeva ostvarena konačna točnost manja od 30%, s izuzetkom pete rečenice u kojoj je SVM klasifikatorom dobivena najveća ostvarena točnost od 60%. Samim time prosječna ostvarena točnost kod prvog subjekta iznosi 22% za SVM odnosno 32% za CNN. Kod petog subjekta neefikasnost predloženog sučelja je posebno izražena, gdje su oba klasifikatora ostvarila prosječnu točnost od oko 8%, a maksimalna točnost od 25% ostvarena je u prvoj rečenici primjenom CNN klasifikatora.

Validacija točnosti predloženog BCI sustava za pisanje bez iteracije odnosno uz jednu prezentaciju ciljanog slova pokazala je vrlo izvrsnu točnost kod trećeg i četvrtog subjekta, dobre točnosti kod prvog i drugog subjekta s potencijalom daljnjeg napredovanja, te vrlo loše rezultate kod petog subjekta, zbog čega sa sigurnošću možemo potvrditi da predloženi sustav nije primjenjiv kod navedenog subjekta. S obzirom da se traženo slovo odabire na temelju niza od 22 stimulacije bez ponavljanja istovjetnih stimulacija, ostvarene točnosti svakako su pozitivan rezultat usporediv sa state – of – the – art sučeljima za pisanje. Osim toga, primjena segmenta bez iteracije istovjetnih stimulacija ima pozitivan efekt na *ITR* što je važna mjera efikasnosti sučelja mozak-računalo. Prema [2], *ITR* na svakom segmentu opisan je sljedećom relacijom:

$$ITR\left(\frac{bits}{segment}\right) = log_2 N + P log_2 P + (1-P) log_2\left(\frac{1-P}{N-1}\right), \tag{5.1}$$

gdje $N = 22$ predstavlja broj stimulacija unutar jednog segmenta, a P konačnu točnost klasifikacije sustava. Za prikaz *ITR* u bitovima po minuti, (5.1) potrebno je pomnožiti sa 2.6 što predstavlja broj segmenata unutar jedne minute (trajanje jednog segmenta uključujući visoko frekventni zvuk kao signalizaciju završetka segmenta iznosi 23 sekunde). Ostvarene *ITR* vrijednosti u bitovima po minuti za sve subjekte i sve napisane rečenice prikazane su u tablici 5.1. Svakako valjalo bi istaknuti dobivene vrijednosti kod trećeg i četvrtog subjekta pri prvom i drugom mjerenju, gdje je vrijednost od 9.44 bita/min kod trećeg subjekta izrazito dobar rezultat za sučelja mozak-računalo s auditornim podražajima.

Smanjenje duljine trajanja segmenta kako je predloženo u eksperimentalnoj metodi kroz upotrebu ne-iterirajućeg pristupa svakako ima pozitivan utjecaj na *ITR*, međutim negativno utječe na točnost klasifikacije kod nekih subjekata zbog smanjene količine informacija korištenih pri klasifikaciji. Analizom (5.1.) i dobivenih *ITR* vrijednosti jasno je da nedovoljna točnost veliki problem u radu sučelja, te da bi se za uspješno korištenje sustava kod nekih subjekata svakako trebala povećati točnost, prvenstveno kroz dodatno prikupljanje neuroloških reakcija na stimulacije odnosno produljeno vrijeme trajanja segmenta.

U tu svrhu na rezultatima prikazanim na slici 5.3. za svako mjerenje i svakog subjekta pored plave veličine koja određuje konačnu točnost klasifikacije dodan je i crveni stupac koji određuje vjerojatnost da se ciljana stimulacija nalazi u skupu pet stimulacija sa najboljim klasifikacijskim rezultatom. Na taj način zapravo je prikazana mogućnost poboljšanja konačne točnosti sustava unutar pojedinog segmenta ako subjektu nakon prvog niza od 22 stimulacija unutar kojeg nije bilo moguće izdvojiti jednu dominantnu stimulaciju, ponovimo pet najdominantnijih stimulacija, te se izmjerene neurološke reakcije koriste kao mehanizam poboljšanja točnosti sustava. Promatrajući dobivene rezultate vidljivo je da bi predloženo ponavljanje stimulacija doprinijelo poboljšanju konačne točnosti kod svih subjekata. Najveće poboljšanje točnosti moguće je kod prvog i drugog subjekta gdje bi primjena ponavljanja stimulacija doprinijela poboljšanju točnosti od 30% za SVM i 40% za CNN kod prvog subjekta, te oko 30% neovisno o klasifikatoru za drugog subjekta. Također kod trećeg i četvrtog subjekta predložena naknadna iteracija dominantnih stimulacija daje prostora za dodatno poboljšanje od 15-20%, s time da je u nekim rečenicama moguća i 100% točnost. Kod petog subjekta također je moguće poboljšanje konačne točnosti sustava, međutim čak ni maksimalno moguće povećanje točnosti neće biti dovoljno za normalno korištenje sustava.

U većini slučajeva konvolucijska neuronska mreža osigurala je nešto veću mogućnost poboljšanja točnosti, što bi neuronsku mrežu učinilo pogodnijim klasifikatorom u slučaju

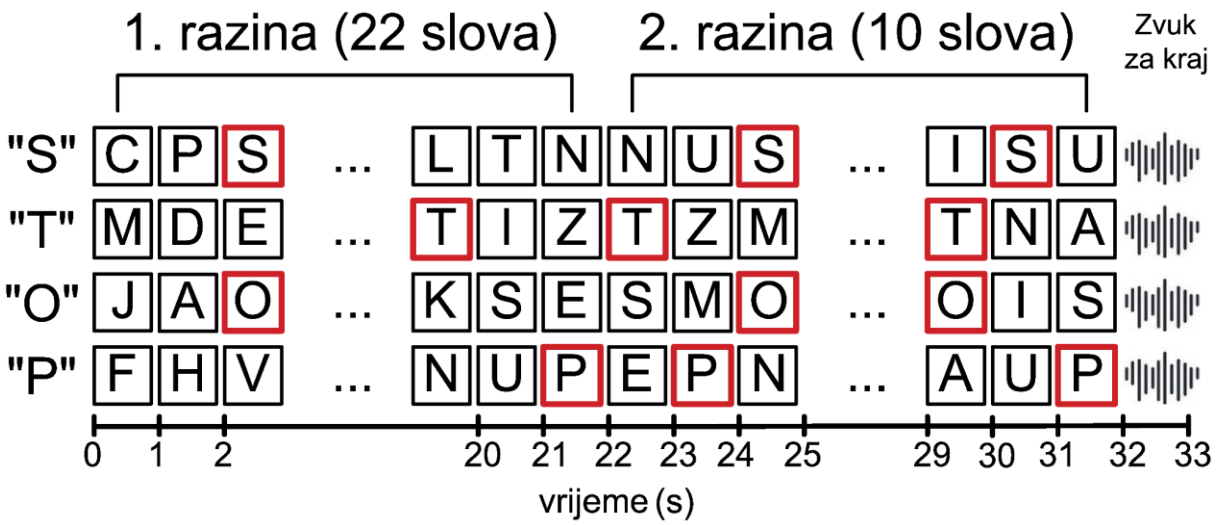
Tablica 5.1. Ostvarene *ITR* vrijednosti za sve rečenice i sve subjekte korištenjem obje predložene klasifikacijske metode.

Subjekt		*ITR*(bita/min) redni broj rečenice						
		1	2	3	4	5	6	srednja vrijednost
1	SVM	0.070	1.197	0.474	0.070	4.571	0.135	1.077
	CNN	0.00	1.197	1.874	1.874	3.295	2.682	1.821
2	SVM	2.790	3.832	3.832	1.095	2.866	3.748	3.027
	CNN	2.790	3.832	5.00	2.790	2.074	2.074	3.093
3	SVM	7.765	5.418	2.515	1.982	4.719	6.303	4.784
	CNN	9.445	5.418	3.295	6.652	3.747	5.00	5.593
4	SVM	7.765	5.088	3.295	8.453	4.719	7.655	6.181
	CNN	6.303	8.453	1.599	7.222	2.866	6.303	5.457
5	SVM	0.00	0.00	0.070	0.474	0.00	0.135	0.113
	CNN	0.923	0.268	0.070	0.00	0.00	0.00	0.210

dodatne prezentacije najznačajnijih stimulacija. Unatoč direktnom negativnom utjecaju na *ITR* zbog povećanja trajanja segmenta, očekivano poboljšanje točnosti sustava u konačnici bi trebalo dovesti do povećanja *ITR*-a.

5.3. Modifikacija sučelja mozak-računalo

Implementacija prethodno opisane ideje rezultirala je novom konfiguracijom eksperimentalne metode, koja se sada sastoji od dvije klasifikacijske razine, a prikazana je na slici 5.4. Prva klasifikacijska razina istovjetna je prethodnoj eksperimentalnoj metodi, te se sastoji od niza od 22 nasumično poredana slova koji se prezentiraju korisniku u intervalu od jedne sekunde. Unutar prve razine sustav nastoji pronaći samo jednu stimulaciju koja predstavlja ciljano slovo, te u slučaju da unutar navedene razine postoji samo jedna stimulacija čija se klasifikacijska sigurnost ističe od ostalih stimulacija, sustav odabire najsigurnije slovo kao ciljano i korisniku se visokofrekventnim zvukom označava kraj segmenta i prebacivanje fokusa na sljedeće slovo rečenice. Drugim riječima sustav se ponaša identično eksperimentalnoj metodi predloženoj u poglavlju 3.1. Jedinstvena klasifikacija u prvoj razini određena je pomoću dvije metode. U prvoj metodi zadaje se minimalna klasifikacijska vrijednost koju stimulacija mora zadovoljiti. U slučaju da postoji samo jedna stimulacija s klasifikacijskim rezultatom



Slika 5.4. Predložena arhitektura BCI sustava za pisanje u dvije klasifikacijske razine.

većim od navedenog nivoa sustav odabire navedenu stimulaciju kao ciljani podražaj. Druga metoda traži jedinstvenu stimulaciju čija je klasifikacijska vrijednosti barem za tri standardne devijacije veća od srednje vrijednosti klasifikacijskih rezultata svih stimulacija u prvoj razini.

U slučaju da prva razina nije rezultirala jedinstvenom klasifikacijom, korisniku se po dva puta u nasumičnom redoslijedu ponavljaju stimulacije iz seta pet stimulacija s najvećom klasifikacijskom sigurnošću iz prethodne razine. Na taj način postoji mogućnost da se dodatno validiraju rezultati prve klasifikacijske razine, odnosno poboljša konačna točnost sustava. Predložena arhitektura u dvije razine posebno je korisna kada korisnik slučajno reagira na neko od ne-ciljanih prezentiranih slova. Korištenjem druge klasifikacijske razine subjektu je dana mogućnost korekcije i odabira ispravnog slova.

Prema modificiranoj strukturi BCI sustava rezultati prve klasifikacijske razine zapravo su ulaz u drugu razinu, što je zapravo izvedivo jedino u izvedbi sustava u stvarnom vremenu unutar koje nema značajnijeg kašnjenja između prve i druge klasifikacijske razine. Naime, prema prethodnoj implementaciji sustava u kojoj se podaci naknadno obrađuju po završetku mjerenja, nije moguće pripremiti aktualne stimulacije za drugu razinu sustava. Zbog toga, validacija predložene metode izvršena je tako da je ulazni niz od pet najdominantnijih stimulacija *ad-hoc* određen prije samog početka mjerenja, te se sastoji od ciljanog slova (korisniku je točno definirana rečenica koju treba napisati) i četiri nasumična ne-ciljana slova. U slučaju da nakon prve razine imamo siguran odabir, EEG mjerenja iz druge faze se zanemaruju i ciljano slovo se odabire iz prve faze. U situaciji kada prva faza nije bila dovoljno uspješna, a ciljano slovo se nalazi unutar skupa pet najdominantnijih stimulacija pristupa se analizi neuroloških reakcija na

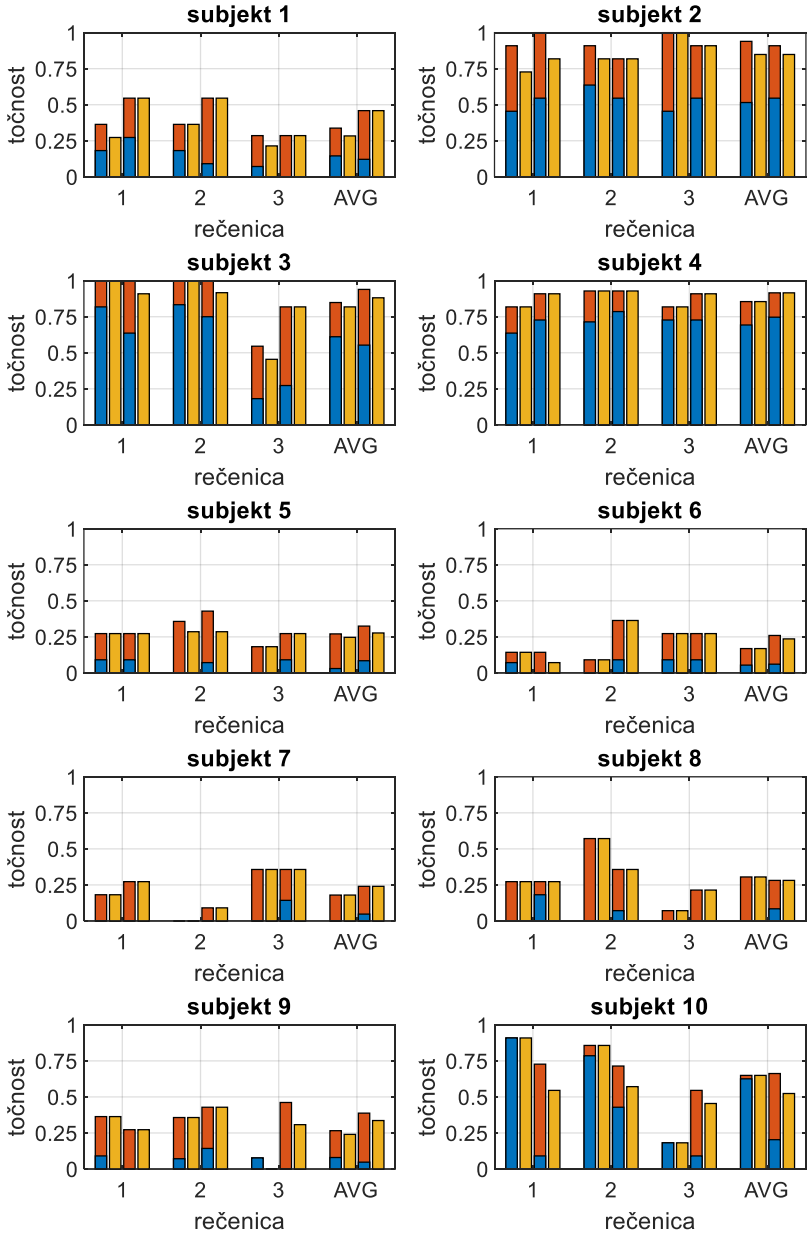
ponovljeni niz stimulacija, te se na temelju dobivenih rezultata odabire ciljano slovo. Završetak druge faze praćen je visokofrekventnim zvukom što ujedno označava i kraj trenutnog i početak sljedećeg segmenta.

5.4. Rezultati validacije sučelja mozak-računalo za pisanje u dvije klasifikacijske razine

Novo definiranu konfiguraciju sučelja mozak-računalo za pisanje u dvije klasifikacijske razine potrebno je ponovo validirati kroz set mjerenja u kojima korisnici kao i u poglavlju 5.2 moraju uz pomoć sustava napisati već predložene rečenice. Radi bolje validacije sustava dodatnih pet korisnika koji nisu imali prethodnog iskustva s BCI sustavima, uključeno je u testiranje te je na njima prije predviđenih mjerenja izvršen postupak opisan u poglavljima 4.3 i 5.1. Nakon što je za svakog od pet dodatnih korisnika istreniran vlastiti *xDAWN* prostorni filter, te SVM i CNN klasifikatori, korisnici su se dovoljno upoznali sa sustavom te su pristupili zadatku pisanja rečenica.

Zadatak svakog subjekta iz grupe 10 osoba bio je napisati tri već predložene i korištene rečenice, a dobiveni rezultati prikazani su na slici 5.5. Svaka rečenica predstavljena je sa četiri stupca, gdje se prva dva stupca odnose na rezultate dobivene *xDAWN* i SVM metodom, a posljednja dva na rezultate dobivene CNN klasifikatorom. U zadnjem stupcu označenim *AVG* prikazane su prosječne vrijednosti na sve tri rečenice za oba tipa klasifikatora. Kao i u prethodnoj analizi sustava sa samo jednom razinom klasifikacije, veličina prikazana plavom bojom u neparnim stupcima predstavlja konačnu točnost sustava ako su slova odabrana samo analizom prvog niza od 22 stimulacija, dok vrijednosti prikazane crvenom bojom u istim stupcima predstavljaju vjerojatnost da se ciljano slovo nalazi u skupu pet najdominantnijih stimulacija koje će se prema novodefiniranoj strukturi sustava u drugoj klasifikacijskoj razini ponovo prezentirati korisniku. Konačna točnost nakon analize neuroloških reakcija s ponovljenim setom stimulacija prikazana je žutom bojom, te zapravo predstavlja konačnu točnost sustava s dvije razine.

Ostvareni rezultati pokazuju ponovo odličnu točnost sustava kod trećeg i četvrtog subjekta, ali i vrlo dobre rezultate kod prvog i drugog subjekta, čiji rezultati u prethodnom korištenju sustava nisu odgovarali rezultatima dobivenim validacijom istreniranih klasifikatora. Kod trećeg subjekta u prve dvije rečenice ostvarena je maksimalna točnost nakon druge klasifikacijske razine primjenom *xDAWN* i SVM klasifikatora, dok je za iste rečenice uz CNN



Slika 5.5. Rezultati točnosti kod pisanja rečenica za svih deset subjekata primjenom *xDAWN* i SVM klasifikatora (prva dva stupca u svakoj rečenici) odnosno CNN klasifikatora (posljednja dva stupca u rečenici). Plavom bojom označena je konačna točnost sustava nakon prve klasifikacijske faze, dok je žutom prikazana konačna točnost sustava nakon druge klasifikacije faze. Kao i u prethodnom poglavlju crvenom bojom označena je vjerojatnost da se ciljana stimulacija nakon prve klasifikacijske razine nalazi u skupu pet stimulacija s najvišim klasifikacijskim vrijednostima.

ostvarena konačna točnost od 90%. U obje rečenice korištenje druge klasifikacijske razine doprinijelo je poboljšanju konačne točnosti BCI sustava, koja je nakon prve razine ovisno o klasifikatoru varirala između 60-80%. Veliki pad točnosti u trećoj rečenici primjenom SVM klasifikatora, gdje je ostvarena vrijednost od 45%, te veoma dobar rezultat u istoj rečenici korištenjem CNN klasifikatora od 75% utjecao je na nešto bolju prosječnu točnost ostvarenu CNN klasifikatorom koja iznosi odličnih 90%. Iako je u obje prve rečenice došlo do povećanja točnosti nakon naknadne klasifikacijske razine, rezultati u trećoj rečenici primjenom CNN klasifikatora ukazuju na pravi potencijal druge razine nakon koje je točnost s 25% porasla na nešto manje od 81%.

Treći subjekt također je ostvario izvrsne rezultate s oba tipa klasifikatora, gdje je primjenom SVM klasifikatora ostvarena prosječna točnost od 85%, a primjenom CNN klasifikatora 91%. Korištenjem SVM metode u prvoj i trećoj rečenici ostvarene su točnosti od 81%, te 90% u drugoj rečenici, dok je primjena CNN klasifikatora osigurala konstantnu točnost od 91% na svim rečenicama. Kao i u rezultatima kod trećeg subjekta, druga klasifikacijska razina osigurala je povećanje točnosti sustava, a CNN se pokazao kao robusniji klasifikator, čiji su klasifikacijski rezultati stabilniji. Veoma slični rezultati ostvareni su i kod drugog subjekta, gdje se nakon prve klasifikacijske razine za oba klasifikatora točnost kretala između 45-60%. Korištenjem ponovljenih stimulacija sustav je u svim rečenicama uspio značajno povećati točnost, tako da je u slučaju SVM klasifikatora točnost varirala između 70 i 100%, a u slučaju CNN klasifikatora između 80 i 90% dodatno podupirući tezu o nešto robusnijem rezultatima ostvarenim CNN klasifikatorom. Ostvarene prosječne konačne točnosti za oba tipa klasifikatora iznose 85%, čime je točnost u prosjeku povećana 30-35%.

Kod prvog subjekta također imamo poboljšanje rezultata u usporedbi s prethodnim korištenjem sustava, kada je u prosjeku ostvarena točnost od 32% primjenom CNN klasifikatora, koji je i u ovim mjerenjima pokazao bolje rezultate od SVM klasifikatora. U prve dvije rečenice CNN klasifikatorom ostvarena je točnost od 55% nakon druge klasifikacijske razine, što je povećanje od 25% odnosno 45% u odnosno na prvu razinu. Slaba ostvarena točnost u trećoj rečenici od samo 25% utjecala je na pad konačne prosječne točnosti ispod 50%. Predloženi prošireni BCI sustav kod petog subjekta također je ostvario poboljšanje konačne točnosti u odnosu na sustav s jednom razinom, međutim prosječna vrijednost od 25%, kolika je i vrijednost na sve tri rečenice primjenom CNN klasifikatora nedovoljna je za uspješno korištenje predloženog sustava.

Dodatnih pet subjekata uključenih u istraživanje ostvarili su rezultate slične onima kod petog

subjekt, za koje se prosječna ostvarena konačna točnost kretala između 25 i 30%. Za subjekte 6 - 9 u većini rečenica ostvarena je točnost od 25% s maksimalnom vrijednošću od 50%. Dobiveni rezultati ukazuju na to da subjekti 5 - 9 nisu u stanju koristiti predloženi BCI sustav, odnosno da je za uspješno korištenje sustava, ako je ono uopće moguće, potrebno puno više praktične primjene. Uspješni rezultati ostvareni su kod posljednjeg desetog subjekta kod kojeg je SVM metoda dala bolje rezultate od CNN klasifikatora pomoću kojeg je ostvarena prosječna točnost od 52%. Tako je primjenom SVM klasifikatora ostvarena konačna točnost od 91% za prvu rečenicu odnosno 81% za drugu, s time da su dobivene vrijednosti ostvarene već nakon prve klasifikacijske razine. Veoma loša točnost u trećoj rečenici od samo 20% smanjila je prosječnu ostvarenu točnost SVM klasifikatora na 65%. Rezultati dobiveni CNN klasifikatorom još jednom su potvrdili robusnost navedenog klasifikatora, tako da je konačna točnost sustava nakon druge razne u sve tri rečenice varirala između 45 i 55%. Detaljniji prikaz točnosti sustava nakon prve i druge faze, te promjena u točnosti uzrokovana drugom klasifikacijskom razinom kao i ostvarene *ITR* vrijednosti nakon svake faze za svakog subjekta i svaku rečenicu prikazani su u tablici 5.2.

Ostvarena brzina prijenosa podataka prema (5.1) direktno korelira sa ostvarenom točnošću, tako da je povećanjem točnosti nakon druge faze u svim situacijama došlo i do povećanja *ITR*-a, osim kod desetog subjekta pri korištenju SVM klasifikatora. Naime, kod navedenog subjekta prosječno poboljšanje točnosti nakon druge razine klasifikacije iznosi 2.4% (na sve tri rečenice za samo jedno slovo je promijenjena odluka nakon druge faze), zbog čega je produljeno vrijeme trajanja svakog segmenta zbog dodatne faze utjecalo na smanjenje *ITR*-a, koji je u prosjeku sa 5.714 bita/min pao na 4.268 bita/min. Svakako bi valjalo napomenuti i ostvaren *ITR* u prvoj rečenici nakon prve razine, gdje je sa 90% točnošću ostvaren *ITR* od 9.44 bita/min. Osim posljednjeg subjekta, *xDAWN* i SVM dali su neznatno bolji rezultat *ITR*-a i kod drugog subjekta, pogotovo zbog toga što je stopostotna točnost u prvoj rečenici dala maksimalnu vrijednost *ITR*-a koju je moguće ostvariti predloženim BCI sustavom u dvije klasifikacijske razine, a iznosi 8.108 bita/min.

Maksimalne teoretske vrijednosti *ITR*-a ostvarene su kod trećeg subjekta u prvoj i drugoj rečenici primjenom SVM klasifikatora, međutim loša izvedba u trećoj rečenici od 1.945 bita/min rezultirala je nešto boljim prosječnim rezultatima kod CNN klasifikatora, koji iznose 6.228 bita/min. Povrh toga, kod trećeg subjekta primjenom CNN klasifikatora na sve tri rečenice ostvaren je izvrstan *ITR* od 6.583 bita/min odnosno 6.862 bita/min tako da je navedeni subjekt ostvario najbolju prosječnu vrijednost od 6.676 bita/min. Dobivene vrijednosti kod

Tablica 5.2 Prikaz rezultata ostvarenih primjenom predloženog BCI sustava za pisanje u dvije klasifikacijske razine. Pored točnosti prikazane su i ostvarene *ITR* vrijednosti nakon obje klasifikacijske razine kao i ostvarena poboljšanja primjenom druge klasifikacijske razine.

Subjekt	Redni broj rečenice	Točnost nakon 1. razine (%)		Točnost nakon 2. razine (%)		Poboljšanje točnosti (%)		Prosječno poboljšanje točnosti (%)		ITR nakon 1. razine(bits/min)		Prosječan ITR nakon 1. razine (bits/min)		ITR nakon 2. razine (bits/min)		Prosječan ITR nakon 2. razine (bits/min)	
		SVM	CNN	SVM	CNN	SVM	CNN	SVM	CNN	SVM	CNN	SVM	CNN	SVM	CNN	SVM	CNN
1	1	18.2	27.3	27.3	54.5	9.1	27.2	10.8	33.7	0.47	1.09	0.32	0.38	0.76	2.67	0.85	2.06
	2	18.2	9.1	36.3	54.5	9.1	45.4			0.47	0.07			1.30	2.67		
	3	7.1	0.0	21.4	28.6	14.3	28.6			0.02	0.00			0.47	0.83		
2	1	45.4	54.5	72.7	81.8	27.3	27.3	33.4	30.3	2.70	3.83	3.57	3.83	4.39	5.41	5.97	5.80
	2	63.6	54.5	81.8	81.8	18.2	27.3			5.00	3.83			5.41	5.41		
	3	45.4	54.5	100	90.9	54.6	36.4			2.79	3.83			8.10	6.58		
3	1	81.8	63.6	100	90.9	18.2	27.3	20.7	32.8	7.75	5.00	5.42	4.24	8.10	6.58	6.05	6.22
	2	83.3	75.0	100	91.6	16.7	16.6			8.02	6.65			8.10	6.69		
	3	18.2	27.3	45.4	81.8	27.2	54.5			0.47	1.09			1.94	5.41		
4	1	63.6	72.7	81.8	90.9	18.2	18.2	16.2	16.9	5.00	6.30	5.80	6.60	5.41	6.58	5.90	6.67
	2	71.4	78.5	92.8	92.8	21.4	14.3			6.10	7.22			6.86	6.86		
	3	72.7	72.7	81.8	90.9	9.1	18.2			6.30	6.30			5.41	6.58		
5	1	9.1	9.1	27.3	27.3	18.2	18.2	21.6	19.3	0.07	0.07	0.02	0.05	0.76	0.76	0.64	0.79
	2	0.0	7.1	28.5	28.5	28.5	21.4			0.00	0.02			0.83	0.83		
	3	0.0	9.1	18.2	27.3	18.2	18.2			0.00	0.07			0.33	0.76		
6	1	7.1	0.0	14.3	7.1	7.2	7.1	11.5	17.5	0.02	0.00	0.03	0.04	0.19	0.02	0.33	0.70
	2	0.0	9.1	9.1	36.4	9.1	27.3			0.00	0.07			0.05	1.31		
	3	9.1	9.1	27.3	27.3	18.2	18.2			0.07	0.07			0.74	0.76		
7	1	0.0	0.0	18.2	27.3	18.2	27.3	17.9	19.3	0.00	0.00	0.00	0.09	0.33	0.76	0.53	0.69
	2	0.0	0.0	0.0	9.1	0.0	9.1			0.00	0.00			0.00	0.05		
	3	0.0	14.3	35.7	35.7	35.7	21.4			0.00	0.27			1.26	1.26		
8	1	0.0	18.2	27.3	27.3	27.3	9.1	30.5	19.7	0.00	0.47	0.00	0.16	0.76	0.76	1.22	0.83
	2	0.0	7.1	57.1	35.7	57.1	28.6			0.00	0.02			2.89	1.26		
	3	0.0	0.0	7.1	21.4	7.1	21.4			0.00	0.00			0.02	0.47		
9	1	9.1	0.0	36.3	27.3	27.3	27.3	16.0	28.8	0.07	0.00	0.04	0.09	1.31	0.76	0.86	1.16
	2	7.1	14.3	35.7	42.8	28.5	28.5			0.02	0.27			1.26	1.75		
	3	7.7	0.0	0.0	30.7	-7.7	30.7			0.03	0.00			0.00	0.96		
10	1	90.1	9.1	90.1	54.5	0.0	45.4	2.4	32.2	9.44	0.07	5.71	0.88	6.58	2.67	4.27	2.53
	2	78.5	42.3	85.7	57.1	7.2	14.8			7.22	2.52			5.89	2.89		
	3	18.2	9.1	18.2	45.4	0.0	36.3			0.47	0.07			0.33	1.94		

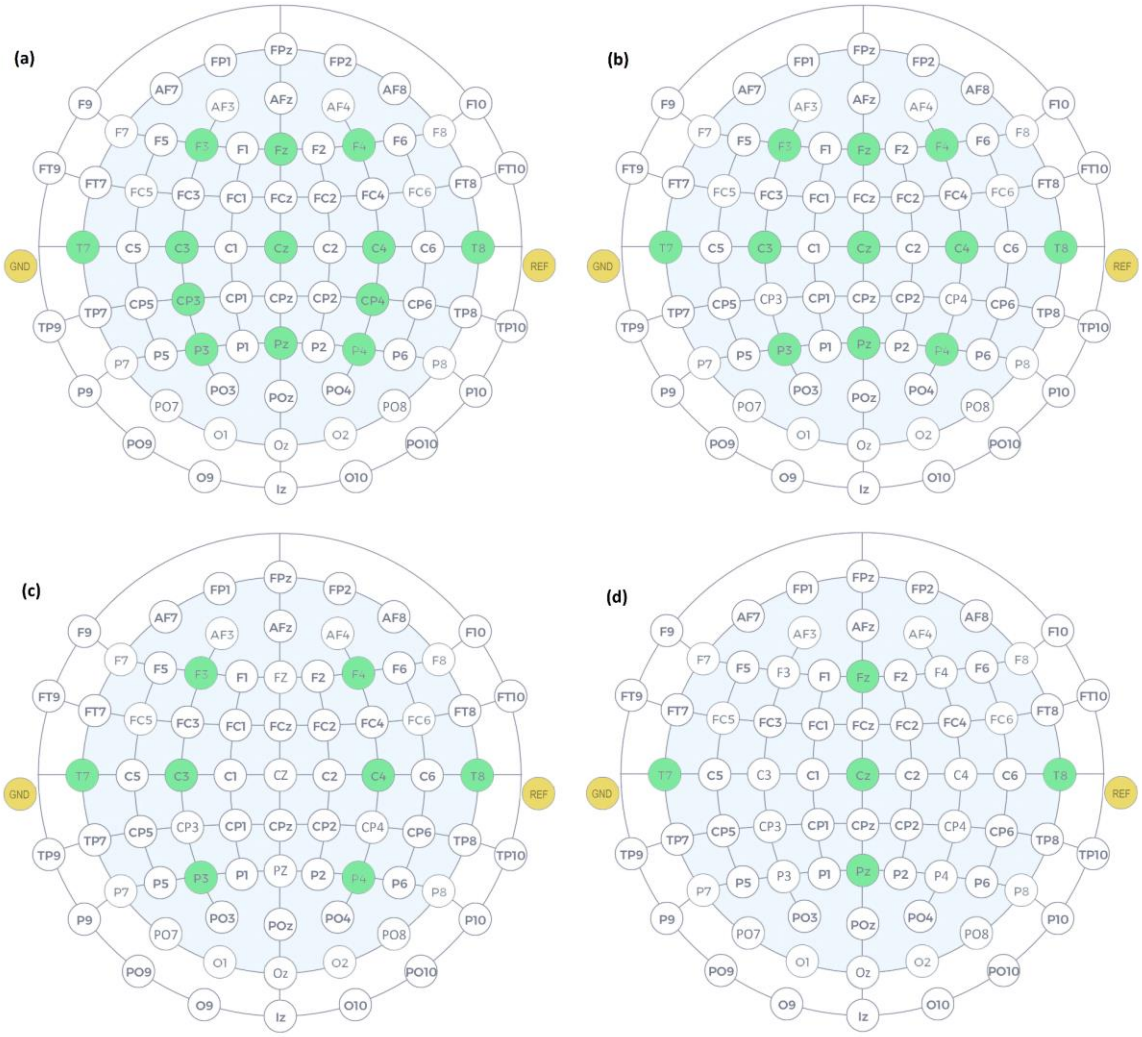
subjekata 1-4 i 10 usporedive su sa *ITR* vrijednostima kod drugih auditornih BCI sustava s vizualnom asistencijom, dok je u usporedbi sa sličnim auditornim sustavima baziranim na nizu slova ostvareno značajno poboljšanje u točnosti i brzini prijenosa podataka. Ostali subjekti ostvarili su nedovoljno dobre rezultate koji su bliže rezultatima ostvarenim u istraživanju [74].

5.5. Analiza utjecaja smanjenja broja elektroda na točnost sučelja mozak-računalo

Rezultati korištenja predloženog BCI sustava uz primjenu potpune konfiguracije elektroda prikazane na slici 4.2. pokazali su vrlo dobre i izvrsne rezultate kod prva četiri i zadnjeg desetog subjekta. Iz navedenog razloga analiza efikasnosti predloženog sučelja na različitim konfiguracijama sa smanjenim brojem EEG mjernih elektroda provedena je na navedenim subjektima. Cilj analize je reduciranje broja elektroda s dosada korištenih 16 mjernih elektroda, te pronalaženje konfiguracije s manjim brojem mjernih elektroda čiji će rezultati treniranja klasifikatora i pisanja rečenica objašnjenih u prethodnim poglavljima dati još uvijek zadovoljavajuće dobre rezultate. U tu svrhu predložene su četiri nove konfiguracije elektroda gdje svaka sljedeća ima manji broj mjernih elektroda od prethodne.

Prva konfiguracija na slici 5.6a je konfiguracija s uklonjenim elektrodama u okcipitalnoj regiji (PO7, Oz, PO8), te se sastoji od 13 mjernih elektroda. Prvi razlog uklanjanja navedenih elektroda leži u činjenici da je sustav prvenstveno namijenjen osobama koji se nalaze u ležećem položaju zbog čega navedene elektrode mogu izazvati nelagodu i pritisak na navedeni dio lubanje. Drugi razlog je činjenica da okcipitalna regija teorijski ne bi trebala biti aktivna u korištenju predloženog sučelja, zbog činjenice da je njezina uloga obrada vizualnih stimulacija što je u ovom slučaja izbjegnuto zatvaranjem očiju prilikom provedbe eksperimenta. Ova je činjenica donekle osporena kroz analizu moždanih aktivnosti primjenom ICA metode, gdje je kod drugog subjekta analiza pokazala izvor nezavisne moždane aktivnosti u predjelu okcipitalne regije (nezavisna komponenta 5, slika 4.12). Kako je već objašnjeno dobivena komponenta moždane aktivnosti može biti rezultat primjene ICA algoritma i pogrešne DIPFIT lokalizacije, a ne stvarni izvor neurološke aktivnosti zbog čega je uklanjanje navedenih elektroda opravdano i u slučaju drugog subjekta.

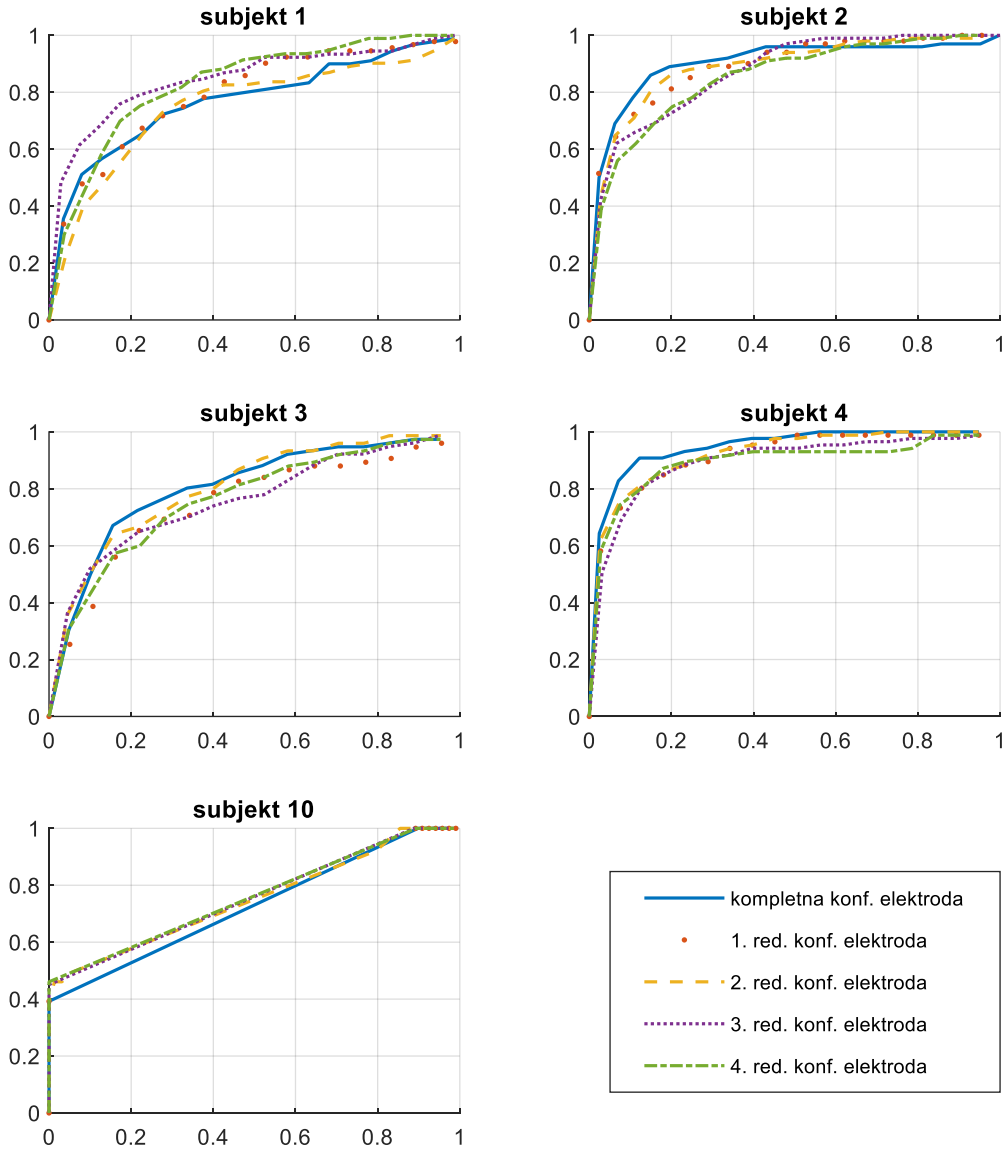
Sljedeća konfiguracija na slici 5.6b razlikuje se od prethodne konfiguracije elektroda po tome što su dodatno uklonjene dvije elektrode na prijelazu iz centralne i parijetalne regije (CP3, CP4). Na taj način frontalna, centralna i parijetalna regija pokrivene su svaka s tri mjerne elektrode dok su temporalne regije (lijeva i desna) pokrivene svaka s jednom mjernom



Slika 5.6. Prikaz reduciranih konfiguracija elektroda korištenih u analizi točnosti sustava. (a) prva reducirana konfiguracija bez okcipitalnih elektroda; (b) druga reducirana konfiguracija; (c) treća reducirana konfiguracija bez okcipitalnih i centralnih elektroda; (d) četvrta reducirana konfiguracija elektroda.

elektrodom. Konfiguracija broj 3 prikazana na slici 5.6c, sastoji se od 8 mjernih elektroda, te su s obzirom na prethodnu konfiguraciju izostavljene centralne elektrode frontalne, centralne i parijetalne regije (Fz, Cz, Pz), dok je temporalna regija ostala nepromijenjena. Posljednja konfiguracija sastoji se od pet mjernih elektroda te je svaka regija pokrivena samo s jednom elektrodom, odnosno frontalna, centralna i parijetalna s elektrodama postavljenim uzduž moždane pukotine koja odvaja lijevu i desnu hemisferu mozga (Fz, Cz, Pz), dok su temporalne regije pokrivene već korištenim T7 i T8 elektrodama.

Definiranjem reduciranih konfiguracija mjernih elektroda, u sljedećem koraku su



Slika 5.7. Rezultati treniranja klasifikatora s reduciranim konfiguracijama EEG elektroda prikazani u obliku ROC krivulja. Kod prvog do četvrtog subjekta korištena je CNN metoda dok je kod desetog subjekta korišten *xDAWN* prostorni filter u kombinaciji sa SVM klasifikatorom.

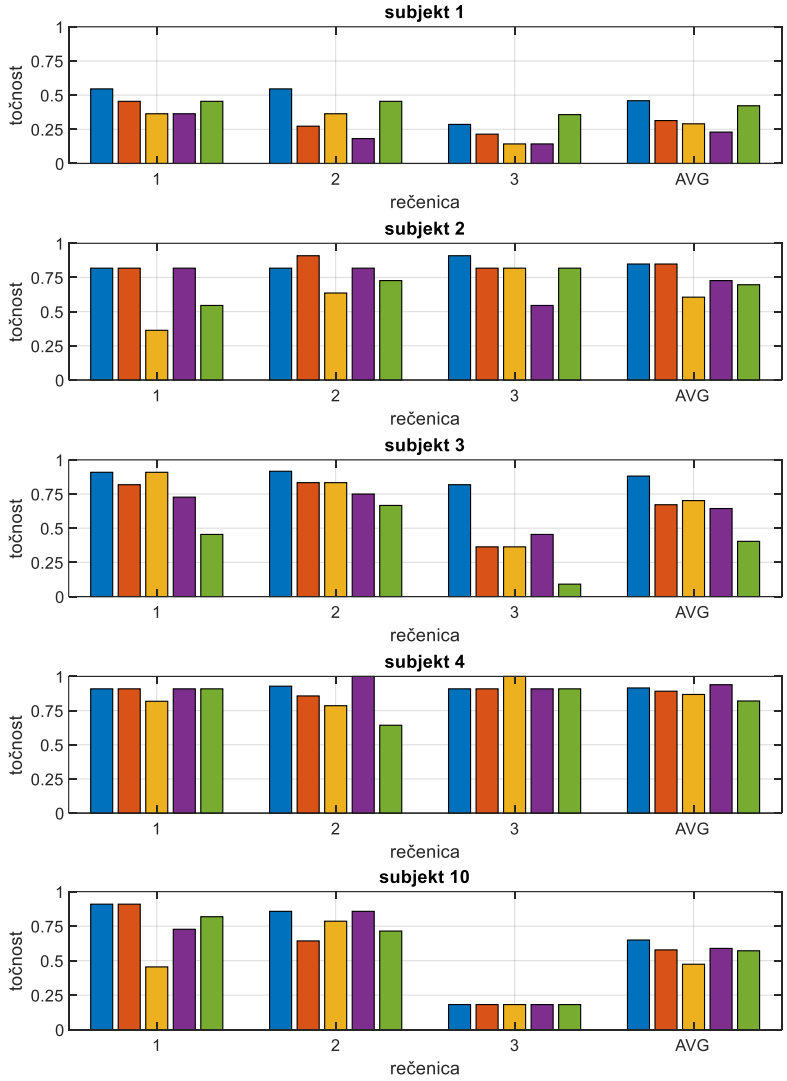
pripremljeni EEG podatci prva četiri i desetog subjekta. EEG podatci za treniranje, obrađeni su način da su za svaku konfiguraciju iz mjerenja uklonjeni svi EEG signali s elektroda koje se ne nalaze unutar promatrane konfiguracije. Novi reducirani setovi podataka korišteni su za učenje CNN klasifikatora kod prva četiri subjekta, gdje je neuronska mreža pokazala nešto bolje rezultate, dok je kod posljednjeg desetog subjekta SVM pokazao značajnije bolje rezultate, što

je razlog korištenja navedene klasifikacijske metode za potrebe ove analize. Kao i u prethodnim slučajevima treniranja klasifikatora podatci su nasumično odabrani u omjeru 70% za treniranje i 30% za validaciju naučenog klasifikatora. Rezultati treniranja klasifikatora u obliku ROC krivulja za svakog subjekta prikazani su na slici 5.7. Za svakog subjekta prikazane su ROC krivulje za sve navedene konfiguracije, gdje prva krivulja prikazuje rezultate originalnog klasifikatora koji je korišten u validaciji sustava za pisanje iz prethodnih poglavlja. Ostatak se odnosi na krivulje dobivene reduciranim setovima s istim omjerom ciljanih i ne-ciljanih stimulacija kao i originalni klasifikator.

Iz prikazanih krivulja možemo zaključiti da potpuna konfiguracija od 16 elektroda najbolje rezultate daje kod drugog, trećeg i četvrtog subjekata koji su ostvarili najbolje rezultate prilikom pisanja rečenica. Za prve tri konfiguracije elektroda kod drugog subjekta nemamo gotovo nikakve razlike u ROC krivulji, zbog čega je za očekivati da će obje reducirane konfiguracije dati jednako dobre rezultate u klasifikaciji napisanih rečenica. Nešto lošije rezultate ostvarile su posljednje dvije konfiguracije, međutim dobivene krivulje sugeriraju da bi i slučaju veće redukcije elektroda sustav trebao imati dovoljno dobru točnost kod drugog subjekta. Slična je situacija i kod trećeg i četvrtog subjekta gdje je razlika između različitih konfiguracija još manja, očekujući također izvrsne rezultate točnosti neovisno o odabranom setu elektroda.

Kod prvog i desetog subjekta imamo zanimljivu situaciju da su neke reducirane konfiguracije postigle nešto bolje rezultate od originalne konfiguracije. Tako su kod prvog subjekta posljednje dvije konfiguracije ostvarile najbolje rezultate u obliku ROC krivulja, međutim razlike ne bi trebale značajno utjecati na konačnu klasifikaciju slova pri pisanju rečenica. Za desetog subjekt, kod kojeg je korišten *xDAWN* i SVM, razlika između predloženih konfiguracija je neznačajna. Ostvareni rezultati ukazuju na veoma malu ovisnost rezultata treniranja klasifikatora o broju elektroda, što bi nadalje trebalo implicirati da će uporaba bilo koje predložene konfiguracije dati u prosjeku usporedive rezultate prilikom klasifikacije napisanih rečenica.

Kako bi potvrdili navedenu pretpostavku, tako istrenirani klasifikatori korišteni su za klasificiranje auditornih stimulacija sučelja mozak-računalo u eksperimentu pisanja rečenica sa dvije klasifikacijske razine predstavljenog u poglavlju 5.3. Za razliku od prethodne vizualizacije rezultata na slici 5.5. na kojoj su za subjekte po rečenici prikazane točnosti nakon prve i druge klasifikacijske razine za obje klasifikacijske metode, te vjerojatnost da se ciljana stimulacija nakon prve klasifikacijske razine nalazi u unutar odabranog seta od 5 stimulacija, rezultati prikazani na slici 5.8. prikazuju samo konačnu točnost sustava. Svaka od tri napisane



Slika 5.8. Rezultati točnosti pisanja rečenica pomoću predloženog sučelja s dvije klasifikacijske razine. Za svakog od prikazanih subjekata novi klasifikatori učeni su na reduciranim setovima podataka određenim konfiguracijom elektroda. Svaka rečenica klasificirana je pomoću klasifikatora prilagođenih predloženim konfiguracijama elektroda, a točnost klasifikacije slova određena je stupcima različitih boja; plava: kompletna konfiguracija elektroda s 16 aktivnih elektroda; crvena: prva reducirana konfiguracija s 13 aktivnih elektroda; žuta: druga reducirana konfiguracija s 11 aktivnih elektroda; ljubičasta: treća reducirana konfiguracija s 8 aktivnih elektroda; zelena: četvrta reducirana konfiguracija s 5 aktivnih elektroda. Posljednja grupa stupaca predstavlja ostvarenu srednju vrijednost po svim rečenicama za svaku od prezentiranih konfiguracija elektroda.

rečenice opisana je s pet ostvarenih konačnih točnosti prezentiranog sustava u obliku stupaca različitih boja, a koji predstavljaju pet različitih konfiguracija mjernih elektroda.

Promatrajući dobivene rezultate možemo primijetiti varijacije u točnosti kod subjekta u ovisnosti o odabranoj konfiguraciji, te u nekim situacijama konfiguracija s manjim brojem elektroda daje nešto bolje rezultate u odnosu na konfiguracije s višim brojem elektroda. Posebno je to vidljivo kod prvog subjekta kod kojeg prva i posljednja konfiguracija daju gotovo identične rezultate kroz sve tri rečenice, dok je ostatak konfiguracija ostvarilo u najboljem slučaju 20% lošiju točnost. Globalno gledajući, možemo ipak potvrditi da potpuna konfiguracija elektroda daje najbolje rezultate, međutim prva reducirana konfiguracija u kojoj nisu sadržane tri elektrode iz okcipitalne regije također u prosjeku daje gotovo identične rezultate. Značajnija razlika je jedino vidljiva kod trećeg subjekta, sto se može objasniti sa vrlo lošom točnosti u trećoj rečenici, te bi se sa većim skupom rečenica navedena razlika vjerojatno smanjila. Dobiveni rezultat svakako je pozitivan jer je time problem udobnosti korištenja sustava riješen uz vrlo mali utjecaj na konačnu točnost sustava. Zanimljiva je svakako i činjenica da druga reducirana konfiguracija u kojoj su uz okcipitalne elektrode dodatno uklonjene elektrode Cp3 i Cp4 postavljene na granici centralne i parijetalne regije u prosjeku ostvaruje nešto lošije rezultate, što je posebno istaknuto kod prvog, drugog i desetog subjekta. Kod četvrtog subjekta koji je ostvario najbolje rezultate prilikom korištenja predloženog sučelja, broj elektroda nije značajno utjecao na konačnu točnost sustava, tako je za najgoru posljednju konfiguraciju ostvarena najmanja točnost od 82%, dok je najbolja točnost ostvarena kod potpune i treće reducirane konfiguracije te iznosi 92% odnosno 94%.

Dobiveni rezultati sugeriraju da se kod osoba koje uspješno mogu koristiti predloženi sustav za pisanje rečenica, broj elektroda značajno može reducirati bez velikog utjecaja na konačnu točnost sustava. To je posebno vidljivo iz rezultata ostvarenih kod drugog, četvrtog i desetog subjekta gdje prosječna razlika u točnosti sustava nije varirala značajno osim za drugu reduciranu konfiguraciju kod drugog i desetog subjekta. Za trećeg subjekta posljednja konfiguracija daje najlošije rezultate, koja je jedina ostvarila prosječnu točnost od 40% što je pad od 48% u usporedbi s punom konfiguracijom. Ostale reducirane konfiguracije pokazale su se kao uspješne pogotovo u prve dvije rečenice, gdje je najlošija točnost ostvarena za treću reduciranu konfiguraciju te iznosi oko 75%, dok su prva i druga reducirana konfiguracija ostvarile vrijednosti između 80 i 90%.

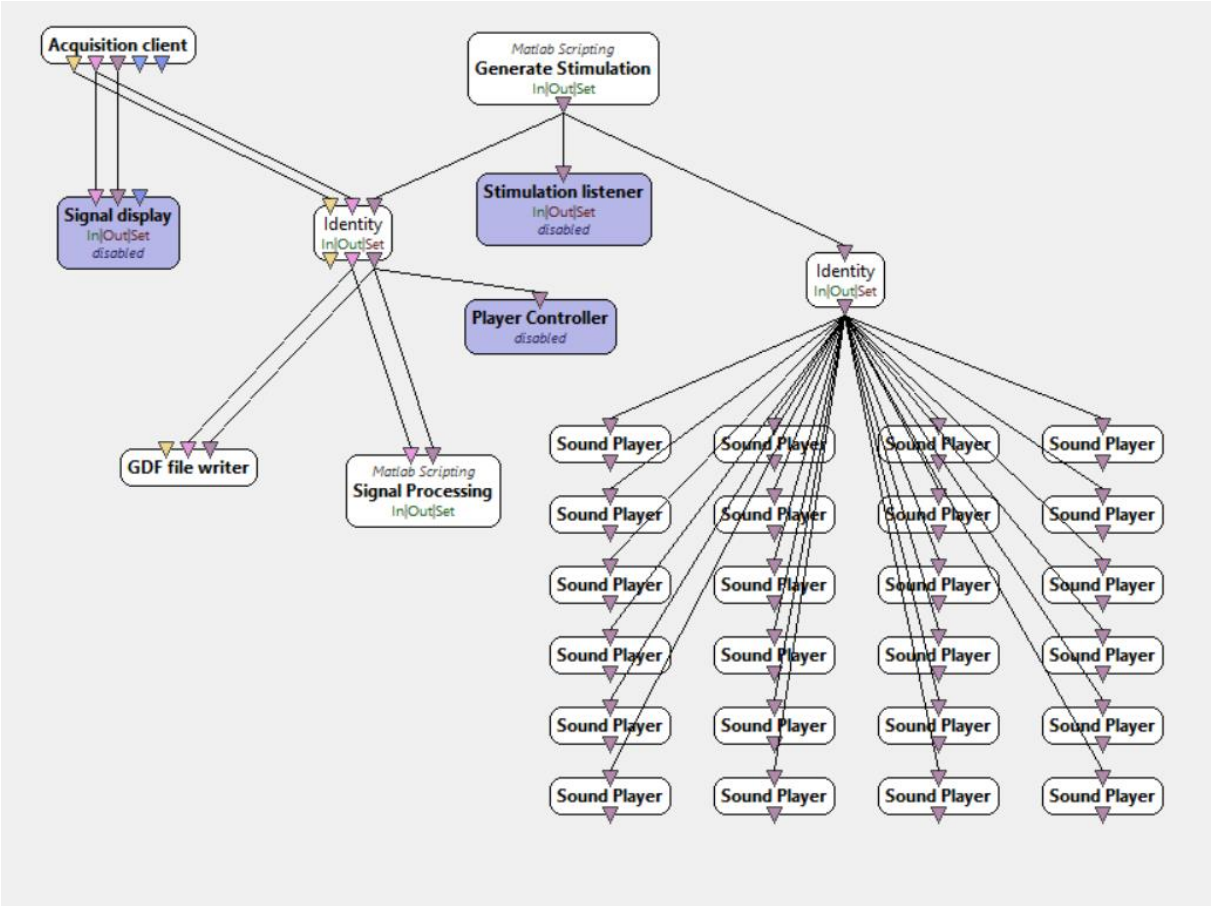
6. Sučelje mozak-računalo za pisanje u stvarnom vremenu

Arhitektura sučelja mozak-računalo za pisanje rečenica na principu auditornih stimulacija s dvije klasifikacijske razine predložena u poglavlju 5.3 pokazala je optimalni kompromis između brzine pisanja slova odnosno trajanja segmenta i konačne točnosti sustava. Predloženom strukturom tako je moguće dobiti bolji prijenos informacija kroz povećanje točnosti primjenom druge klasifikacije razine odnosno produljenjem trajanja segmenta kod subjekata sa slabijim odzivom na stimulaciju. Nasuprot tome, kod subjekata s dobrim odzivom na stimulaciju, odabir stimulacije uslijediti će vjerojatno već nakon prve klasifikacijske razine što će opet pozitivno utjecati na *ITR*. Kako je predložena arhitektura sustava sekvencijalna (izlaz prve klasifikacijske razine je ulazu u sljedeću), s ciljem što manjeg kašnjenja između dvije klasifikacijske faze u kojem može doći do gubitka koncentracije od strane subjekta, javlja se potreba za izvedbom sustava u stvarnom vremenu minimizirajući vrijeme trajanja pauze između dvije faze.

6.1. Izvedba sustava u stvarnom vremenu

Predloženi sustav u stvarnom vremenu izveden je u *OpenVibe* razvojnom okruženju unutar kojeg se pozivaju MATLAB funkcije za generiranje stimulacija, obradu i klasifikaciju prikupljenih EEG mjerenja, te generiranje povratne informacije o odabranom slovu prema korisniku sustava. Implementacija u stvarnom vremenu sadrži funkcijske blokove čija se funkcionalnost nije promijenila, s obzirom na prethodno opisanu implementaciju, kao što su *Acquisition client* ili *Sound Player* blokovi koji su objašnjeni u poglavlju 3.2. Izvedba sustava u *OpenVibe*-u prikazana je na slici 6.1.

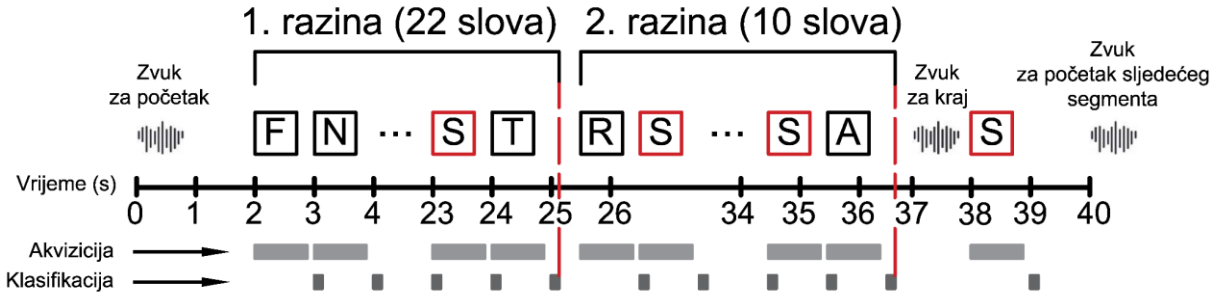
S obzirom na prethodnu izvedbu gdje je obrada podataka uslijedila nakon mjerenja, predloženi sustav u stvarnom vremenu mora osigurati povratnu informaciju korisniku o odabranom slovu nakon svakog segmenta. Iz tog razloga kraj segmenta više nije određen jednostavnom zvučnom stimulacijom u obliku visokofrekventnog monotonog zvuka, već je određen sekvencom visokofrekventni zvuk – odabrano ciljano slovo. Na taj način korisniku se



Slika 6.1. Izvedba BCI sustava za pisanje u *OpenVibe* razvojnom okruženju. *Generate Stimulation* i *Signal Processing* blokovi pozivaju MATLAB .m funkcije odgovorne za generiranje stimulacija, te akviziciju, pred-obradu i klasificiranje mjerenih EEG signala.

prezentira slovo koje je sustav odabrao, čime je omogućena interakcija sustava s korisnikom. Povrh toga niz od 22 slova odnosno stimulacija iz prve klasifikacijske razine proširen je za dodatnu stimulaciju „POVRATAK“, čijim je odabirom omogućen povratak na prethodno slovo. Navedena stimulacija je opcionalna, odnosno moguće ju je uključiti/isključiti kako će biti objašnjeno u nastavku teksta. Kompletna arhitektura sustava unutar jednog segmenta prikazana je na slici 6.2.

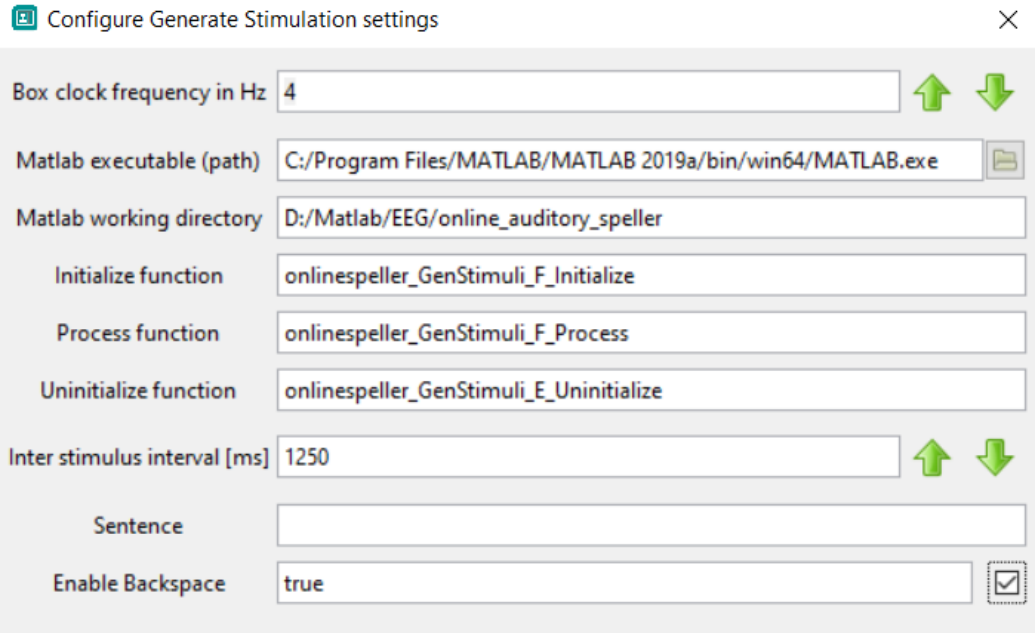
Prema arhitekturi predloženog sustava za pisanje svaki segment odnosno traženo slovo određeni su prvim nizom od 22 slova uz mogućnost uključivanja dodatne 23 stimulacije koja omogućuje povratak na prethodno slovo, odnosno po potrebi drugim nizom sastavljenim od pet najdominantnijih stimulacija iz prve razine, te povratnom vezom kako je već napomenuto. Koordinacija sustava odnosno koordinacija stimulacija definirana je bloku *Generate Stimuli*, unutar kojeg su definirane MATLAB funkcije koje se pozivaju samo jednom pri



Slika 6.2. Prikaz arhitekture predloženog BCI sustava za pisanje primjenom auditornih podražaja u stvarnom vremenu. Nakon visokofrekventnog zvuka za početak segmenta, pauza od jedne sekunde omogućava korisniku pripremu na prvo slovo stimulacijskog niza. Ovisno o klasifikacijskim rezultatima u prvoj razini, moguće je preskakanje druge klasifikacijske razine, te direktan prelazak na krajnju sekvencu visokofrekventni zvuk – ciljano slovo, čime je segment definiran vremenski intervalom od cca. 28s odnosno cca. 40s u slučaju dvije klasifikacijske razine. U slučaju odabira mogućnosti povratka na prethodno slovo, prva klasifikacijska razina je proširena za dodatnu simulaciju čime je ukupno trajanje segmenta produženo za jednu sekundu. Okviri crvene boje označavaju ciljanu stimulaciju/slovo.

inicijalizaciji i deinicijalizaciji sustava, te MATLAB funkcije koja se ciklički poziva s podesivom frekvencijom između 1 i 128 Hz, a zadužena je za upravljanje *Stimulation* kanala prema ostatku sustava. Pristup postavkama bloka Generate Stimuli moguće je pristupiti dvostrukim pritiskom na *Generate Stimuli* blok prilikom čega se otvara prozor prikazan na slici 6.3.

Osim navedenih parametara bloka, unutar prozora podesiva su i dodatna tri parametra sustava, a to su *Inter Stimulus Interval* odnosno vremenski interval između dvije stimulacije izražen u milisekundama, a koji je u ovom slučaju podešen na 1250ms. Druga varijabla *Sentence* odnosi se na riječ ili rečenicu koju je potrebno napisati što nije obavezno polje kako je i prikazano na slici 6.3, dok je posljednjim parametarom omogućena kontrola opcije za brisanje odnosno povratka na prethodno slovo rečenice. Da bismo sačuvali što veću količinu računalnih resursa, koji će biti potrebni za akviziciju i klasifikaciju EEG mjerenja odnosno epoha, odabrana je prilično niska frekvencija pozivanja *Process* funkcije od 4 Hz, čime je definirana vremenska rezolucija, odnosno minimalno vrijeme između dvije stimulacije od 250ms. Prema definiranim parametrima navedeni blok svake sekunde generira novu stimulaciju koja će akustički biti prezentirana korisniku, preko jednog od stimuliranih *Sound Player* blokova, te prosljeđuje informaciju o trenutno aktivnoj stimulaciji dalje prema ostalim

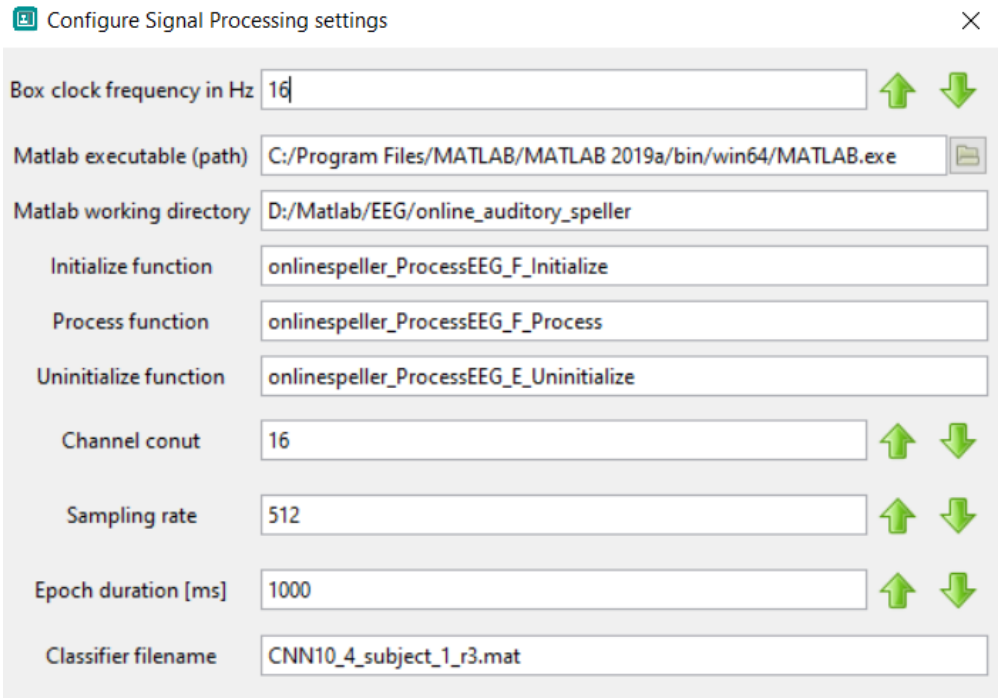


Slika 6.3. Prikaz parametara *Generate Stimulation* bloka za koordiniranje sustava i generiranje niza auditornih stimulacija.

blokovima u sustavu.

Signal Processing blok koji će u nastavku biti detaljnije objašnjen, prikuplja podatke sinkronizirano s aktivacijom nove stimulacije, te prikupljene podatke pred-obrađuje, klasificira, te rezultate povratno šalje u blok za koordinaciju sustava. Prema slici 6.2 arhitektura sustava je implementirana tako da je svaka epoha obrađena i klasificirana odmah nakon što je prikupljena, odnosno dok je aktivna akvizicija sljedeće EEG epohe. To znači da je za vrijeme trajanja prve stimulacije u segmentu aktivna samo akvizicija EEG epohe, dok se u svim sljedećim stimulacijama uz akviziciju sljedeće EEG epohe, paralelno vrši obrada prethodne EEG epohe. Na taj način vrijeme čekanja između prve i druge klasifikacijske razine, svedeno je na 250-500ms za obradu i klasifikaciju, što je u potpunosti prihvatljivo za praktičnu implementaciju sustava.

Nakon obrade stimulacija, sustav prema predloženoj arhitekturi, na temelju rezultata klasifikacije odabire jednu ciljanu stimulaciju i koordinira završetak segmenta ili odabire ulazak u novu klasifikacijsku razinu gdje se niz od pet najdominantnijih slova ponovo prezentiraju korisniku. Isto kao i u prethodnoj fazi sustav paralelno prikuplja i klasificira epohe, po čijem završetku se odabrano slovo auditorno prezentira korisniku kao povratna informacija. Prema arhitekturi sustava na slici 6.2. u završnoj fazi segmenta, odabranom ciljanom stimulacijom



Slika 6.4. Prikaz parametara *Signal Processing* bloka za prikupljanje, obradu i klasifikaciju EEG signala neurološke aktivnosti.

evocirani potencijal se također mjeri, obrađuje i klasificira, a dobiveni rezultat služi kao dodatna razina određivanja sigurnosti odabrane stimulacije, na temelju koje bi sustav mogao dodatno upravljati redoslijedom stimulacija. Prvotna ideja je da se dobiveni rezultat koristi kao sredstvo upravljanja povratkom na prethodno slovo, odnosno da se stimulacija POVRATAK ubaci u niz stimulacija sljedećeg segmenta u slučaju male vjerojatnosti da se radi o ciljanoj stimulaciji. Iako bi navedena ideja potencijalno skratila vrijeme trajanja stimulacija sljedećeg segmenta za jednu sekundu (izostavljanjem stimulacije POVRATAK) čime bi se povećao *ITR*, dodatna varijabilnost sustava otežala bi analizu efikasnosti navedene opcije i smanjila upotrebljivost sustava. Iz navedenog razloga, uključivanje opcije za povratak na prethodno slovo automatski povećava prvi segment za dodatnu 23. stimulaciju smanjujući nepotrebnu varijabilnost. Unatoč tome, predložena provjera ciljanog slova može poslužiti kao dobra početna točka za daljnji razvoj sustava zbog čega je implementirana u strukturu sustava, unatoč negativnom utjecaju na *ITR*.

Prema parametrima servera za akviziciju EEG mjernih podataka koji omogućava komunikaciju *OpenVibe*-a i BrainProducts V-Amp16 akvizicijskog uređaja, EEG podatci šalju se u paketima od 32 uzorka po elektrodi, odnosno jedan paket predstavlja matricu dimenzija

16x32, gdje broj redaka matrice odgovara broju korištenih EEG elektroda. Uz duljinu trajanja epohe od jedne sekunde, kao i u prethodnim izvedbama sustava, i frekvenciju uzorkovanja EEG uređaja od 512 Hz, *Signal Processing* blok odnosno odgovarajuća *Process* funkcija mora prihvatiti 16 podatkovnih paketa kako bi prikupila sve EEG podatke koji pripadaju aktivnoj epohi. Iz tog razloga, frekvencija izvršavanja *Process* funkcije iznosi 16 Hz, što je vidljivo na slici 6.4 koja prikazuje podesive parametre bloka *Signal Processing*. Osim standardnih parametara kao funkcije za inicijalizaciju, de-inicijalizaciju i kontinuirano pozivanje, korisnik mora unijeti dodatne vrijednosti kao što su broj kanala EEG uređaja, frekvencija uzorkovanja EEG signala, duljina trajanja epohe izražena u milisekundama koja je u ovom slučaju 1000 ms, te naziv .mat datoteke *Classifier filename* koja sadrži informacije o korištenom klasifikatoru za klasifikaciju prikupljenih EEG epoha. Naime, vrlo dobri rezultati koji su dobiveni primjenom oba tipa predloženih klasifikatora potaknulo je izvedbu sustava koja podržava oba tipa klasifikatora. U slučaju da ime datoteke sadrži skraćenicu „CNN“ sustav prepoznaje neuronsku mrežu kao odabrani klasifikator, dok se u slučaju prisutnosti skraćenice „SVM“ u nazivu datoteke učitavaju parametri za *xDAWN* i SVM klasifikator.

Nakon što *Process* funkcija iz bloka *Signal Processing* primi sve podatkovne pakete povezane s aktivnom stimulacijom od strane *Acquisitin Client* bloka, te ih posloži u EEG matricu dimenzija 16x512, započinje se pred-obrada signala. Za potrebe sustava u stvarnom vremenu filtriranje se vrši samo s nisko-propusnim filterom granične frekvencije 40 Hz, za razliku od prethodne implementacije gdje se filtriranje vrši pojasno-propusnim filterom. Razlog tome je nedovoljan broj podataka za uspješno filtriranje pojasno-propusnim filterom navedenih karakteristika, kao i vrijeme filtriranja, koje nije moguće odraditi u vremenskim okvirima ovog sustava u stvarnom vremenu. Kao veoma dobra zamjena za navedeno filtriranje odabrana je metoda uklanjanja srednje vrijednosti epohe, koja je računski i vremenski puno manje zahtjevnija, a ostvaruje zadovoljavajuće rezultate. Povrh toga, prilikom *offline* obrade signala, korištena je metoda uklanjanja artefakata iz EEG signala pomoću ICLabel sustava, za koji je prethodno potrebno raščlaniti mjerenja u nezavisne komponente primjenjujući ICA metodu, što u navedenoj arhitekturi sustava također vremenski nije moguće izvesti. Slično kao i sa visoko-propusnim filterom, uspješno raščlanjivanje EEG signala na nezavisne komponente zahtjeva da se analiza provede na čitavom segmentu, što je u direktnoj kontradikciji sa arhitekturom sustava koja vrši klasifikaciju po epohama u stvarnom vremenu. Iz navedenih razloga, uklanjanje artefakata izostavljeno je iz predloženog sustava, unatoč negativnom utjecaju na točnost sustava. Međutim, analiza mjerenja iz prethodnog poglavlja pokazala je jako mali broj

detektiranih i uklonjenih artefakata, vjerojatno kao posljedica zatvorenih očiju tijekom eksperimenta, zbog čega detekcija i uklanjanje artefakata u ovom slučaju djeluje kao redundantna operacija koja se može izostaviti bez značajnijeg utjecaja na rad sustava.

Filtrirani signal nadalje se pod-uzrokuje četiri puta tako da je nova frekvencija uzorkovanja 128 Hz, te je tako dobiveni signal ulaz u CNN klasifikator ili dodatno filtrira xDAWN filterom prije korištenje SVM klasifikatora. Govoreći o prvoj klasifikacijskoj fazi, rezultati klasificiranja svih 22 stimulacija odnosno epoha spremljeni su u polje, iz kojeg blok za upravljanje sustavom *Generate Stimuli* nakon završetka prve faze određuje daljnje korake. U drugoj fazi vrši se identičan proces stimuliranja, prikupljanja, obrade i klasifikacije podataka nakon kojeg dolazi do konačnog odabira traženog slova.

6.2. Rezultati korištenja sučelja mozak – računalo za pisanje u stvarnom vremenu

Validacija sustava za pisanje u stvarnom vremenu izvršena je na subjektima koji su prilikom prethodnog korištenja sustava ostvarili barem prosječnu 50% točnost nakon druge klasifikacijske razine, što je ostvareno kod prvog do četvrtog i desetog subjekta. CNN klasifikator korišten je za klasificiranje EEG epoha kod prva četiri subjekta, dok je kod posljednjeg subjekta korišten *xDAWN* i SVM zbog boljih rezultat koji su ostvareni naspram CNN klasifikatora. U prvom dijelu sesije, prema konfiguraciji eksperimenta isključena je opcija za povratak na prethodno slovo, čime je sustav konfiguriran prema originalnoj verziji u dvije klasifikacijske razine opisanoj u poglavlju 5.3. Zadatak svakog subjekta je pisanje sljedeće tri jednostavne rečenice: „DAJ MI MALO VODE“, „BOLI ME GLAVA“ i „UPALI MUZIKU“, tako da je kao i u prethodnim slučajevima izostavljen razmak između riječi. Iako je svaku rečenicu trebalo napisati jedanput, svi subjekti osim trećeg subjekta zatražili su ponavljanje svih ili samo nekih rečenica kako bi poboljšali ostvarene točnosti pisanja. Dobiveni rezultati pisanja za sve subjekte prikazani su u tablici 6.1.

Prvi subjekt ponovio je sve rečenice dva puta, čime je ukupno napisao šest rečenica. U prvoj iteraciji samo u posljednjoj rečenici subjekt je uspio ostvariti točnost od barem 50%, dok je u drugoj rečenici uspješno napisao samo jedno slovo predložene rečenice. U sljedećoj iteraciji subjekt je značajno povećao svoju točnost, te je u posljednjoj rečenici ostvarena točnost od 60% koja je dovoljna da bi se naknadnom obradom rječnikom uspjelo odgonetnuti njeno pravo

značenje. U svakom slučaju, točnost od 85% u prvoj rečenici je dovoljna za razumljivu komunikaciju, sugerirajući da je kod prvog subjekta moguće postići visoke razine točnosti, iako je još uvijek prisutan problem velike varijabilnosti koja se pojavljuje čak i unutar samih rečenica. Navedeni problem vidljiv je u drugom pokušaju rečenice broj dva, kao i u oba pokušaja rečenice broj tri, u kojima nakon niza od dva do četiri točno klasificirana slova, slijedi niz netočno odabranih stimulacija. Ovakva pojava vjerojatno će u još većoj mjeri biti prisutna kod krajnjih korisnika sustava.

Treći subjekt pokazao je veliku sposobnost korištenja predloženog sustava pomoću kojeg je ostvario prosječnu točnost pisanja od izvrsnih 92%. Tako je u prvoj rečenici krivo klasificirao samo jedno slovo, u drugoj je ostvareno savršenih 100%, dok je u trećoj rečenici prvo i zadnje slovo riječi „MUZIKU“ zamijenjeno slovom S. Iako ne tako jasno vidljiv kao u prethodnim sesijama, primjetan je pad točnost s porastom broja napisanih rečenica. Subjekt 4 dva puta je pisao prvu i drugu rečenicu, dok je posljednja rečenica pisana samo jedanput. U prvom pisanju prve rečenice subjekt je ostvario 62%, dok je u sljedećem pokušaju zbog kratkog pada koncentracije subjekta došlo do pogrešnog brojanja slova. Naime, kako je prikazano u tablici 6.1. subjekt je uspješno napisao prvih pet slova rečenice odnosno prve dvije riječi, kao i prvo slovo sljedeće treće riječi (slovo „M“). Navedeno slovo ujedno je i prvo slovo druge riječi koja je već uspješno napisana. U tom trenutku subjekt zaboravlja da trenutno piše treću riječ te pretpostavlja da je upravo napisao prvo slovo druge riječi i da je sljedeće traženo slovo „I“. Umjesto „I“ sustav je prepoznao „H“ kao traženo slovo dok je u nastavku subjekt nastavio sa rečenicom i kompletno uspješno napisao treću riječ. Iz razloga što je došlo do dupliciranja druge riječi u rečenici treća riječ i prva dva slova posljednje riječi označena su žutom bojom sugerirajući da je subjekt točno napisao slova međutim nije poštovan točan redoslijed. S obzirom da je broj segmenata sustava bio ograničen ukupnim brojem slova u traženoj rečenici, subjekt nije mogao napisati posljednja dva slova koja nisu prikazana u rezultatima. Uzimajući navedeno u obzir, te zanemarujući navedeni pad koncentracije i pomak u slovima možemo zaključiti da je već u sljedećem pokušaju subjekt značajno povećao točnost te uspješno napisao 11 od 13 slova rečenice. Navedeni pad koncentracije i pogreška u praćenju traženog slova primijećena je također kod prvog i posljednjeg desetog subjekta u testnim pokušajima prilikom razvoja sustava koji nisu prikazani, sugerirajući da je za uspješno korištenje sustava ipak potrebna značajna razina mentalne usredotočenosti. Primijećeni događaji će vrlo vjerojatno u još većoj mjeri biti prisutni kod potencijalnih krajnjih korisnika predloženog sustava, što sigurno predstavljati dodatni izazov koji će značajno utjecati na samu korisnost sustava. Ostatak

Tablica 6.1. Ostvareni rezultati pisanja rečenica primjenom predloženog BCI sustava u stvarnom vremenu za svako slovo pisane rečenice. Zelenom bojom označena su točno klasificirana slova, dok su žutom bojom označena također točno klasificirana slova, ali s pomaknutim redoslijedom uslijed gubitka koncentracije subjekta. U stupcu „Broj slova 1. faza“ prikazan je broj slova unutar rečenice kod kojih je izostavljena druga klasifikacijska razina.

Redni broj rečenice	Redni broj subjekta	Rezultati pisanja rečenica primjenom sustava za pisanje u stvarnom vremenu za svako slovo rečenice	Točnost (%)	Broj slova 1. faza	ITR (bit/min)	Trajanja mjerenja (s)
1		D A J M I M A L O V O D E				
	1	D H E M B M O L M V T K L	38.46	1	1.26	508
		D A J M R M A L O V O D O	84.61	2	5.16	497
	2	V A H U C D V C O A D I Z	15.38	1	0.20	508
	3	D A J M I M R L O V O D E	92.31	3	6.26	486
	4	G A J J I D A L O V M L E	69.23	6	4.03	453
		D A J M I M A L O P O	84.62	12	6.63	387
		M H				
	10					
2		B O L I M E G L A V A				
	1	K V R E C P A L U N K	9.09	3	0.05	406
		P O I T M E G G G Z H	36.36	1	1.14	428
	2	B E L E M B R O T V A	45.45	1	1.70	428
		Z R L I M A G L T V T	54.55	6	2.74	398
	3	B O L I M E G L A V A	100	2	7.35	417
	4	G O L I M E G G A V A	81.82	11	6.38	318
		B O L I M E G L A V A	100	11	9.55	318
	10	I C B L H V Z B C V T	9.09	0	0.05	470
		K O L T M U G L J V A	63.63	1	3.05	458
3		U P A L I M U Z I K U				
	1	U R N L A M U U I U I	45.45	0	1.64	439
		H P A E R M M M I K U	54.55	1	2.34	428
	2	N T A L M J U Z L H B	36.36	3	1.23	505
		U P A U B M D Z I O U	63.63	5	3.47	410
	3	U P A L I S U Z I K S	81.82	2	4.91	417
	4	U I A A I M U Z I K U	81.82	10	6.21	329
	10	U P A L C S J H S B F	36.36	4	1.26	422

rečenica četvrti subjekt napisao je s vrlo velikom točnošću tako da je u prvom pisanju druge rečenice ostvarena točnost od 82%, dok je pri drugom pokušaju ostvarena maksimalna točnost. U trećoj posljednjoj rečenici ponovo je dobivena točnost od 82%, čime je ostvarena izvrsna prosječna točnost od 82%.

Slabe rezultate pisanja ostvarili su drugi i deseti subjekt, što nije bilo očekivano s obzirom na vrlo dobre rezultate prilikom validacije predloženog sučelja u dvije klasifikacijske razine. To je posebno vidljivo prilikom pisanja prve rečenice u kojoj je drugi subjekt točno napisao samo 2 od 13 slova rečenice (9% točnosti), dok je deseti subjekt tri puta prekidao mjerenje zbog potpunog gubitka koncentracije, zbog čega rezultati prve rečenice nisu uneseni u tablicu 6.1. Vrlo vjerojatan razlog tome je veliki vremenski interval između dvije sesije zbog čega je prvih nekoliko početnih pokušaja predstavljalo ponovni proces privikavanja na sustav. Za razliku od drugog i desetog subjekta, ostali subjekti koji su sudjelovali u konačnoj validaciji sustava u stvarnom vremenu su povremeno sudjelovali u testiranjima sustava, pa možemo reći da su bili bolje priviknuti na sam sustav. Opažena pojava dodatno ide u prilog tezi da će korištenjem sustava doći i do bolje efikasnosti sustava, što je vidljivo iz mjerenja prilikom pisanja druge i treće rečenice. Naime kod drugog subjekta, već u drugoj rečenici u oba pisanja je ostvarena prosječna 50% točnost, dok je u posljednjoj trećoj rečenici u drugom pisanju ostvareno vrlo dobrih 64%, sugerirajući mogući daljnji napredak u korištenju. Deseti subjekt, prvi značajniji rezultat postigao je u drugom pisanju druge rečenice s ostvarenih 64% točnosti, što je puno bliže očekivanim rezultatima iz poglavlja 5.4. U trećoj rečenici subjekt je početna četiri slova napisao točno, međutim izvrsne rezultate s početka rečenice nije mogao zadržati u nastavku pisanja. Prema vlastitom priznanju subjekta, umor i nemogućnost zadržavanja koncentracije na obavljanje zadatka pisanja u jednom je trenu vodio ka kratkoročnom snu, što u svakom slučaju može objasniti uočeni pad u točnosti nakon četvrtog slova. Dobiveni rezultati još jednom ukazuju na to da je za korištenje sustava potrebna velika razina koncentracije, te da će svaki gubitak iste vrlo vjerojatno rezultirati krivim odabirom slova.

Dodatne informacije o performansama sustava prikazane su u nastavku tablice 6.1. U stupcu „Broj slova 1. faza“ prikazan je broj segmenata odnosno slova rečenice za koje je sustav traženo slovo odabrao već nakon 22 stimulacije, odnosno u kojima je preskočena druga klasifikacijska razina. Razlog je velika razina sigurnosti izdvajanja ciljane stimulacije od ostalih već nakon prve klasifikacijske razine, što nije uvijek rezultiralo točnim odabirom slova. To je vrlo lako vidljivo u rezultatima prvog pisanja druge rečenice kod prvog subjekta, gdje je unatoč tri preskakanja druge klasifikacijske razine, sustav točno klasificirano samo jedno slovo rečenice.

Slična situacija je opažena i kod četvrtog subjekta gdje je u istoj rečenici došlo do dvije pogrešne klasifikacije unatoč tome što je sustav za svako slovo trebao samo prvu razinu klasifikacije. Usprkos navedenim nedostacima, predložena arhitektura pokazala je vrlo velik potencijal kod četvrtog subjekta koji je većinu svojih slova (49/59) napisao primjenom samo prve klasifikacijske faze, kao i kod drugog subjekta koji je 50% slova druge i treće rečenice napisao nakon prve klasifikacijske faze. Izraženijim P300 reakcijama na ciljane stimulacije subjekti su značajno pozitivno utjecali na *ITR*, što je posebno vidljivo u usporedbi ostvarenih *ITR* vrijednosti trećeg i četvrtog subjekta u tablici 6.1. Unatoč tome što su oba subjekta ostvarila idealnu stopostotnu točnost u drugoj rečenici, treći subjekt samo je dva slova napisao primjenom prve faze dok je četvrti subjekt to ostvario kod svih 11 slova. Zbog navedenog, četvrti subjekt je u stanju primjenom auditornog sučelja slati 2.2 bita/min više od trećeg subjekta, a prednost je svakako gotovo 100 sekundi kraće vrijeme trajanja mjerenja kod četvrtog subjekta, što je vidljivo iz posljednjeg stupca tablice. Slična je situacija i u trećoj rečenici gdje je unatoč istoj točnosti četvrtom subjektu trebalo 88 sekundi manje za pisanje rečenice.

U drugoj sesiji uključena je opcija za povratak na prethodno slovo, čime je prva razina određena sa 23 stimulacije. Zadatak subjekata je pisanje pojedinih riječi rečenica iz prethodne sesije, čime je značajno smanjena duljina trajanja mjerenja, međutim subjekt je dužan korigirati odabrano slovo u slučaju krivog odabira. Iako su svi subjekti iz prethodne sesije pristupili zadatku, samo je kod trećeg i četvrtog subjekta ostvarena smislena upotreba predložene funkcionalnosti, zbog čega su u tablici 6.2. prikazani samo rezultati kod navedenih subjekata. Oba korisnika imali su kratku fazu privikavanja na novouvedenu mogućnost sustava, nakon koje su oba subjekta sa izrazito velikom efikasnošću koristili predloženi novitet. Tako je kod trećeg subjekta pri pisanju riječi „MUZIKA“ došlo do pogrešnog odabira prvog slova, dok je pri vjerojatnom pokušaju brisanja prvog slova došlo do odabira slova P umjesto POVRATAK, čime je treći subjekt rečenicu započeo sa dva krivo napisana slova. Povratak na početno slovo riječi moguć je odabirom stimulacije POVRATAK u sljedeća dva segmenta, međutim korisnik je to učinio samo jedanput zbog čega se sustav vratio na pisanje drugog slova riječi. U sljedećim segmentima korisnik je ispravno napisao sva slova te završio pisanje s konačnom točnošću od 83% (5 do 6 slova).

Četvrti subjekt imao je zadatak napisati riječ „VODA“, prilikom čega je triput tražio povratak na prethodno slovo. Nakon točno napisana prva dva slova, u trećem segmentu sustav je odabrao slovo A kao ciljanu stimulaciju, zbog čega u sljedećem segmentu korisnik odabire POVRATAK, koji ga ponovo vraća na pisanje trećeg slova riječi. U nastavku eksperimenta

Tablica 6.2. Prikaz rezultata pisanja riječi primjenom predloženog BCI sustava uz mogućnost korekcije krivo odabranog slova za sva slova pisane rečenice. Zelenom bojom označena su točno odabrana slova ili naredba POVRATAK. Korekcija prethodnog slova od strane subjekta označen je desnom strelicom i prelaskom u novi red.

Redni broj subjekta	Rezultati pisanja riječi uz mogućnost povratka za svako slovo rečenice	Točnost(%)	Broj slova 1. faza	ITR (bit/min)	Trajanje mjerenja (s)
3	M U Z I K A A P ← U Z I K A	75.0	1	4.080	316
4	V O D A V O A ← M ← U ← D A	70.0	10	5.374	298

subjekt je još dva puta korigirao svoj ispravak na istom slovu riječi nakon čega je uspješno napisao posljednja dva slova predložene riječi.

Unatoč izvrsnim rezultatima koje su subjekti ostvarili primjenom mogućnosti povratka, navedena opcija svakako ima i negativne efekte koji bi značajno mogli utjecati na uporabljivost predloženog sučelja. Prvi problem već je uočen kod trećeg subjekta koji je zbog pogrešnog odabira dva uzastopna slova na početku riječi trebao također dva puta odabrati POVRATAK. Nemogućnost da se sa stopostotnom sigurnošću odabere POVRATAK mogao bi uvjetovati iterirajuću sekvencu pogreška – POVRATAK – pogreška – POVRATAK - … Pojavom navedene sekvence ili nemogućnošću točnog odabira povratne naredbe subjekt se neće moći vratiti na prvo pogrešno slovo, što će vjerojatno voditi ka gubitku koncentracije i odustajanja od daljnjeg pisanja rečenice. Iz svega navedenog, jasno je da je uvjet za uspješno korištenje povratka na prethodno slovo vrlo velika točnost kojom subjekt koristi sučelje, zbog čega je mogućnost korekcije slova u predloženoj arhitekturi BCI sustava upitna. Naime, ako subjekt s vrlo velikom točnošću (80% ili više) može pisati rečenice, korekcija odnosno ne-korekcija krivih slova neće previše utjecati na konačnu informaciju koja se želi prenijeti rečenicom. S druge strane, osobe koje imaju manju točnost pisanja korištenjem sustava i koje bi navedenu opciju intenzivnije koristile, nisu u stanju djelotvorno koristiti navedenu mogućnost korekcije

pogreške. Navedeni problemi biti će još izraženiji kod krajnjih korisnika predloženog BCI sustava, zbog čega mogućnost korekcije pogrešnog unosa treba ostati, kako je predloženo, opcionalna varijanta koju je moguće aktivirati ovisno o sposobnostima korisnika.

7. Zaključak

U ovom radu predložena je arhitektura i izvedba sučelja mozak-računalo za pisanje sa auditornim podražajima u stvarnom vremenu koje je namijenjeno osobama koje boluju od sindroma potpuno zaključane osobe. Ideja predloženog BCI sustava je poboljšanje životnog standarda navedenih osoba kroz omogućavanje komunikacije primjenom auditornih podražaja u obliku slova, odnosno fonema iz hrvatskog jezika čime je moguće slaganje riječi i rečenica na način koji je svima poznat. Iz navedenog razloga, predloženi BCI sustav riješio je veliki nedostatak sličnih BCI sustava s auditornim podražajima kod kojih je potrebna vizualna asistencija barem prilikom upoznavanja sa sustavom, čime su takvi sustavi ograničeni na osobe čiji stadij bolesti još nije kompletno utjecao na sposobnost vida, ali postoji tendencija pogoršanja stanja kao što je to slučaj kod osoba koje pate od ALS-a.

Vrlo loš omjer korisnog EEG signala kao odgovora na ciljanu stimulaciju i šuma u koji je uključena i pozadinska neurološka aktivnost nevezana za korištenje BCI sustava uvjetovala je da se u dosadašnjim BCI izvedbama prikupljaju redundantni odzivi na istovjetne stimulacije s ciljem povećanja SNR omjera, a samim time i krajnje točnosti sustava. Takav pristup ne utječe previše na brzinu prijenosa informacija kod BCI sustava s vizualnim podražajima, gdje je smanjenje *ITR*-a zbog ponavljanja istovjetnih stimulacija kompenziran kroz izrazito mali vremenski interval između dvije uzastopne stimulacije. Međutim, primjena auditornih podražaja ovisno o njihovoj kompleksnosti ipak zahtijeva nešto duži period između dviju uzastopne stimulacije kako bi subjekt imao vremena analizirati značenje stimulacije, zbog čega je navedenim pristupom uvelike narušen *ITR*, čineći takve sustava izrazito nepraktične za krajnje korisnike. Povrh toga, neurološke reakcije na vizualne podražaje izraženije su i stabilnije od reakcija na auditorne stimulacije zbog čega izvedba auditornih BCI sustava predstavlja još veći tehnički izazov.

Iz svega navedenog, ideja detekcije ciljane stimulacije na temelju samo jednog odziva, kako je predloženo u ovom radu , čini implementaciju takvog BCI sustava veoma izazovnom, što se može potvrditi izostankom takve implementacije u dosadašnjim istraživanjima. Unatoč tome, rezultati dobiveni primjenom ICA metode na EEG signale evocirane ciljanim stimulacijama pokazali su karakteristične neurološke izvore s tipičnom EEG aktivnosti koja odgovara P300 odzivu. Povrh toga, navedene reakcije kako je prikazano u poglavljima 4.4 i 4.5, s velikom vjerojatnošću pojavljuju se prilikom svakog ciljanog slova, pružajući dodatno ohrabrenje da bi predložena konfiguracija mogla dati pozitivne rezultate barem kod određenog broja subjekata.

Iako se ICA kod nekih subjekata pokazala kao potentna metoda čiji prostorni filter ima sposobnost rastavljanja multi-dimenzionalnog EEG signala u nezavisne izvore neurološke aktivnost, velika računska složenost i potreba za čim bržim sustavom uvjetovala je da se za isticanje značajki signala i klasificiranje odaberu druge pogodnije metode. Iz toga razloga, u ovom radu su odabrane dvije metode, gdje se u prvoj korištenoj metodi za obradu signala tj. za isticanje neurološke aktivnosti povezane s P300 reakcijom koristi *xDAWN* prostorni filter, nakon čega se reducirani set podataka koristi kao ulaz u SVM klasifikator. U drugoj metodi koriste se izvrsna svojstva CNN-a u detektiranju karakterističnih dijelova EEG signala povezanih s P300 odzivom zbog čega u ovoj metodi nema potrebe za prethodnim prostornim filtriranjem EEG-a.

Rezultati dobiveni kroz prvu validaciju predloženog sustava kod pet testnih subjekata potvrdili su dobre mogućnosti sustava, gdje su kod tri od pet subjekata postignuti izvrsni rezultati koji su bolji i robusniji od rezultata sličnog istraživanja u kojima BCI sustav također koristi niz slova. Analizom dobivenih rezultata uvedena je dodatna klasifikacijska razina u kojoj se ponavljanjem stimulacija s najboljim klasifikacijskim rezultatima iz prve razine odnosno niza od 22 slova pokušava poboljšati konačna točnost sustava nauštrb mogućeg lošeg utjecaja na *ITR*. Rezultati ostvareni pisanjem rečenica pomoću sučelja u dvije klasifikacijske razine pokazali su izvrsne rezultate kod četiri od deset subjekata, solidne rezultate kod još jednog subjekta, dok je kod preostalih subjekata ostvarena točnost od 20% nedovoljna za smislenu komunikaciju. Daljnjim korištenjem sustava moguće je poboljšanje točnosti kod nekih od subjekata s lošim rezultatima, međutim velika je vjerojatnost da navedene osobe unatoč treningu neće moći uspješno upravljati sustavom. Obje klasifikacijske metode ostvarile su vrlo dobre, gotovo identične prosječne rezultate pri pisanju tri rečenice, prema kojima se CNN klasifikator ipak pokazao kao nešto efikasnija metoda kod većine subjekata, osim kod desetog subjekta gdje je SVM klasifikatorom ostvarena bolja točnost i brzina prijenosa informacija. Osim navedenog, kod nekih subjekata primijećene su veće oscilacije unutar istih sesija u točnosti pisanja testnih rečenica (pad točnosti s porastom broja napisanih rečenica vjerojatno je povezano s padom koncentracije), gdje se CNN pokazao kao nešto robusnija metoda s manjom varijabilnošću konačne točnosti. U svakom slučaju, obje metode mogu se koristiti za klasifikaciju podataka, gdje je preferiranje SVM metode u početnim fazama korištenja sustava logičniji izbor koji smanjuje potrebno vrijeme. Daljnjim korištenjem sustava prikupljena mjerenja neuroloških reakcija mogu se koristi za učenje CNN klasifikatora, koji zahtijeva više podataka od *xDAWN* i SVM metoda.

Predložena arhitektura BCI sustava u dvije klasifikacijske razine moguća je samo u *online* izvedbi, zbog čega je sustav izveden tako da u stvarnom vremenu prikuplja, obrađuje i klasificira stimulacijom evocirane EEG signale, te korisniku daje povratnu informaciju o odabranom slovu. Konačna izvedba ispitana je na pet subjekata koji su prilikom validacije predložene arhitekture sustava ostvarili prosječnu točnost veću od 50%. Unutar navedene grupe barem dvoje subjekta ostvarilo je izvrsne rezultate točnosti i *ITR*-a, što pogotovo vrijedi za četvrtog subjekta koji je većinu slova napisao unutar prve klasifikacijske razine s točnošću većom od 80%. Izostavljanje druge faze skratilo je vrijeme trajanja eksperimenta i pozitivno utjecalo na *ITR* čime je navedeni subjekt ostvario izvrsnih 9.5 bita/min, što je izrazito velik *ITR* za BCI sustave s auditornim podražajima. Dodatnu mogućnost pruža mogućnost ispravljanja krivo odabranih slova koja je kod trećeg i četvrtog subjekta pokazala vrhunske performanse i omogućila navedenim korisnicima ispravak netočno napisanog slova. Međutim, ispravna upotreba korekcije napisanog slova moguća je samo uz veliku točnost sustava, što nadalje postavlja pitanje potrebe korekcije slova u predloženom BCI sustavu.

Odabir stimulacija u obliku slova i sama arhitektura sustava omogućila je vrlo intuitivno i primjenjivo sučelje mozak-računalo za pisanje koje veliki vremenski interval između stimulacija i mali *ITR* kompenzira na način da koristi samo jednu iteraciju istovjetnih stimulacija. Daljnje poboljšanje sustava kroz povećanje *ITR*-a, moguće je primjenom *auto-correction* sustava koji bi na temelju nekoliko napisanih slova subjektu mogao umjesto slova ponuditi određeni skup riječi, među kojima se vjerojatno nalazi i ona koju subjekt ima namjeru napisati. Druga mogućnost je da se uz primjenu istog sustava za nadopunu slova početni niz od 22 slova formira na način da se najvjerojatnije tražena slova postave pri početku segmenta. U slučaju sigurne klasifikacije jednog od ponuđenih slova, sustav je moguće unaprijediti na način da se prekine izvođenje, preskačući dio prve klasifikacijske razine i cijelu drugu, što će svakako poboljšati *ITR* sustava. Predložene nadogradnje sustava vjerojatno će imati pozitivan utjecaj na korištenje samo kod osoba koje sustav koriste sa već velikom točnošću, čime predložena rješenja neće imati veliki utjecaj na povećanje *ITR*-a i kod ostalih subjekata.

Poboljšanje točnosti, prema vlastitom viđenju problema, moguće je kroz dva istraživačka smjera. Prvi se odnosi na primjenu prostorne distribucije stimulacija kako je već predloženo u nekim znanstvenim radovima. Konkretnije, sustav bi se sastojao od npr. četiri zvučnika prostorno pomaknutih međusobno za 45°, a preko kojih bi se subjekt stimulirao već predloženim podražajima u obliku slova. U tom slučaju osim na značenje stimulacije subjekt se treba fokusirati i na smjer dolaska stimulacije, čime bi se evocirana prostorna neurološka

reakcija mogla pored P300 odziva koristiti za prepoznavanje ciljanih stimulacija. Druga mogućnost koja u svakom slučaju predstavlja potentniju opciju je prikupljanje više neuroloških reakcija povećanjem prostorne rezolucije mjerene metode što je veliki nedostatak EEG uređaja, koji je istaknut u analizi reduciranog broja elektroda na točnost sustava. Prema dobivenim rezultatima, kod osoba koje sučelje koriste s velikom točnošću nije primijećena značajna razlika u točnosti između reduciranih konfiguracija, iako je u posljednjoj konfiguraciji broj elektroda smanjen za skoro 70%. Za ostale subjekte primijećena je nešto veća varijacija, koja je na točnost u prosjeku utjecala oko 20%, čime se postavlja pitanje primjene velikog broja elektroda u BCI svrhe, pogotovo zbog nemogućnosti primjene kompleksnijih alata za obradu signala. Moguće rješenje primjena je fNIRS mjerne metode pored EEG akvizicije čime bi se trebala dobiti nešto bolja razlučivost između neuroloških reakcija na ciljane i ne-ciljane stimulacije. Kašnjenje BOLD reakcije za stimulacijom svakako će predstavljati dodatni svojevrsni izazov u obradi neuroloških signala koji će utjecati na brzinu prijenosa podataka, ali potencijalno osigurati puno bolju točnost sustava i kod subjekata koji nisu uspjeli ostvariti dovoljno dobre rezultate.

Popis referenci

[1] Graimann, B., Pfurtscheller, G., and Allison, B., *Brain-Computer Interfaces*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010.

[2] Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., and Vaughan, T. M., "Brain–computer interfaces for communication and control," *Clin. Neurophysiol.*, vol. 113, no. 6, pp. 767–791, Jun. 2002.

[3] Birbaumer, N., "Breaking the silence: Brain?computer interfaces (BCI) for communication and motor control," *Psychophysiology*, vol. 43, no. 6, pp. 517–532, Nov. 2006.

[4] Sellers, E. W., Ryan, D. B., and Hauser, C. K., "Noninvasive brain-computer interface enables communication after brainstem stroke," *Sci. Transl. Med.*, vol. 6, no. 257, Oct. 2014.

[5] Baniqued, P. D. E. *et al.*, "Brain–computer interface robotics for hand rehabilitation after stroke: a systematic review," *J. Neuroeng. Rehabil.*, vol. 18, no. 1, p. 15, Dec. 2021.

[6] Bell, C. J., Shenoy, P., Chalodhorn, R., and Rao, R. P. N., "Control of a humanoid robot by a noninvasive brain–computer interface in humans," *J. Neural Eng.*, vol. 5, no. 2, pp. 214–220, Jun. 2008.

[7] Vilela, M. and Hochberg, L. R., "Applications of brain-computer interfaces to the control of robotic and prosthetic arms," 2020, pp. 87–99.

[8] Fabiani, G. E., McFarland, D. J., Wolpaw, J. R., and Pfurtscheller, G., "Conversion of EEG activity into cursor movement by a brain-computer interface (BCI)," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 12, no. 3, pp. 331–338, Sep. 2004.

[9] Scherer, R., Lee, F., Schlogl, A., Leeb, R., Bischof, H., and Pfurtscheller, G., "Toward Self-Paced Brain–Computer Communication: Navigation Through Virtual Worlds," *IEEE Trans. Biomed. Eng.*, vol. 55, no. 2, pp. 675–682, Feb. 2008.

[10] Henry, J. C., "Electroencephalography: Basic Principles, Clinical Applications, and Related Fields, Fifth Edition," *Neurology*, vol. 67, no. 11, pp. 2092–2092, Dec. 2006.

[11] REKNEW, "Brain-computer interface systems." [Online]. Available: https://www.ohsu.edu/reknew/brain-computer-interface-systems.

[12] Nunez, P. L. and Srinivasan, R., *Electric Fields of the Brain*. Oxford University Press, 2006.

[13] Berg, P. and Scherg, M., "Dipole models of eye movements and blinks," *Electroencephalogr. Clin. Neurophysiol.*, vol. 79, no. 1, pp. 36–44, Jul. 1991.

[14] Croft, R. J. and Barry, R. J., "Removal of ocular artifact from the EEG: a review," *Neuropshysologie Clin.*, vol. 30, pp. 5–19, 2000.

[15] He, P., Wilson, G., and Russell, C., "Removal of ocular artifacts from electro-encephalography by adaptive filtering," *Med. Biol. Eng. Comput.*, vol. 42, pp. 407–412, 2004.

[16] Nolan, H., Whelan, R., and Reilly, R. B., "FASTER : Fully Automated Statistical Thresholding for EEG artifact Rejection," *J. Neurosci. Methods*, vol. 192, no. 1, pp. 152–162, 2010.

[17] Mognon, A., Jovicich, J., and Bruzzone, L., "ADJUST : An automatic EEG artifact detector based on the joint use of spatial and temporal features," *Psychophysiology*, vol. 48, pp. 229–240, 2011.

[18] Winkler, I., Haufe, S., and Tangermann, M., "Automatic Classification of Artifactual ICA- Components for Artifact Removal in EEG Signals," *Behav. Brain Funct.*, vol. 7, no. 30, pp. 1–15, 2011.

[19] Buzsáki, G., Anastassiou, C. A., and Koch, C., "The origin of extracellular fields and currents — EEG, ECoG, LFP and spikes," *Nat. Rev. Neurosci.*, vol. 13, no. 6, pp. 407–420, Jun. 2012.

[20] Okada, Y., "Neurogenesis of evoked magnetic fields," in *Biomagnetism: An Interdisciplinary Approach*, S. J. Williamson, G.-L. Romani, L. Kaufman, and I. Modena, Eds. Boston, MA: Springer US, 1983.

[21] Hämäläinen, M., Hari, R., Ilmoniemi, R. J., Knuutila, J., and Lounasmaa, O. V., "Magnetoencephalography—theory, instrumentation, and applications to noninvasive studies of the working human brain," *Rev. Mod. Phys.*, vol. 65, no. 2, pp. 413–497, Apr. 1993.

[22] Boto, E. *et al.*, "Moving magnetoencephalography towards real-world applications with a wearable system," *Nature*, vol. 555, no. 7698, pp. 657–661, Mar. 2018.

[23] Mellinger, J. *et al.*, "An MEG-based brain–computer interface (BCI)," *Neuroimage*, vol. 36, no. 3, pp. 581–593, Jul. 2007.

[24] Ogawa, S., Lee, T.-M., Nayak, A. S., and Glynn, P., "Oxygenation-sensitive contrast in magnetic resonance image of rodent brain at high magnetic fields," *Magn. Reson. Med.*, vol. 14, no. 1, pp. 68–78, Apr. 1990.

[25] Buxton, R. B., Uludağ, K., Dubowitz, D. J., and Liu, T. T., "Modeling the hemodynamic response to brain activation," *Neuroimage*, vol. 23, pp. S220–S233, 2004.

[26] McRobbie, D. W., Moore, E. A., Graves, M. J., and Prince, M. R., *MRI from Picture to Proton*. Cambridge University Press, 2006.

[27] Jezzard, Peter; Matthews, M. P. S. M. S., *Functional Magnetic Resonance Imaging*. Oxford University PressOxford, 2001.

[28] Villringer, A., "Non-invasive optical spectroscopy and imaging of human brain function," *Trends Neurosci.*, vol. 20, no. 10, pp. 435–442, Oct. 1997.

[29] Chen, W.-L. *et al.*, "Functional Near-Infrared Spectroscopy and Its Clinical Application in the Field of Neuroscience: Advances and Future Directions," *Front. Neurosci.*, vol. 14, Jul. 2020.

[30] Cui, X., Bray, S., Bryant, D. M., Glover, G. H., and Reiss, A. L., "A quantitative comparison of NIRS and fMRI across multiple cognitive tasks," *Neuroimage*, vol. 54, no. 4, pp. 2808–2821, Feb. 2011.

[31] Warbrick, T., "Simultaneous EEG-fMRI: What Have We Learned and What Does the Future Hold?," *Sensors*, vol. 22, no. 6, p. 2262, Mar. 2022.

[32] Uchitel, J., Vidal-Rosas, E. E., Cooper, R. J., and Zhao, H., "Wearable, Integrated EEG–fNIRS Technologies: A Review," *Sensors*, vol. 21, no. 18, p. 6106, Sep. 2021.

[33] Parvizi, J. and Kastner, S., "Promises and limitations of human intracranial electroencephalography," *Nat. Neurosci.*, vol. 21, no. 4, pp. 474–483, Apr. 2018.

[34] Zardini AS, Rostami B, Najafi K, Hetrick VL, A. O., "Sea of Electrodes Array (SEA): Extremely Dense and High-Count Silicon-Based Electrode Array Technology for High-Resolution High-Bandwidth Interfacing with 3D Neural Structures," *bioRxiv*, 2021.

[35] Ahn, S. and Jun, S. C., "Multi-Modal Integration of EEG-fNIRS for Brain-Computer Interfaces – Current Limitations and Future Directions," *Front. Hum. Neurosci.*, vol. 11, Oct. 2017.

[36] Pfurtscheller, G. and Neuper, C., "Motor imagery activates primary sensorimotor area in humans," *Neurosci. Lett.*, vol. 239, no. 2–3, pp. 65–68, Dec. 1997.

[37] Miner, L. A., McFarland, D. J., and Wolpaw, J. R., "Answering questions with an electroencephalogram-based brain-computer interface," *Arch. Phys. Med. Rehabil.*, vol. 79, no. 9, pp. 1029–1033, Sep. 1998.

[38] Pfurtscheller, G., Guger, C., Müller, G., Krausz, G., and Neuper, C., "Brain oscillations control hand orthosis in a tetraplegic," *Neurosci. Lett.*, vol. 292, no. 3, pp. 211–214, Oct.

2000.

[39] Sutter, E. E., "The brain response interface: communication through visually-induced electrical brain responses," *J. Microcomput. Appl.*, vol. 15, no. 1, pp. 31–45, Jan. 1992.

[40] Klobassa, D. S. *et al.*, "Toward a high-throughput auditory P300-based brain–computer interface," *Clin. Neurophysiol.*, vol. 120, no. 7, pp. 1252–1261, Jul. 2009.

[41] Muller-Putz, G. R., Scherer, R., Neuper, C., and Pfurtscheller, G., "Steady-state somatosensory evoked potentials: suitable brain signals for brain-computer interfaces?," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 14, no. 1, pp. 30–37, Mar. 2006.

[42] Kelly, S. P., Lalor, E. C., Reilly, R. B., and Foxe, J. J., "Visual spatial attention tracking using high-density SSVEP data for independent brain-computer communication," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 13, no. 2, pp. 172–178, Jun. 2005.

[43] Ming Cheng, Xiaorong Gao, Shangkai Gao, and Dingfeng Xu, "Design and implementation of a brain-computer interface with high transfer rates," *IEEE Trans. Biomed. Eng.*, vol. 49, no. 10, pp. 1181–1186, Oct. 2002.

[44] Muller-Putz, G. R. and Pfurtscheller, G., "Control of an Electrical Prosthesis With an SSVEP-Based BCI," *IEEE Trans. Biomed. Eng.*, vol. 55, no. 1, pp. 361–364, Jan. 2008.

[45] CHAPMAN, R. M. and BRAGDON, H. R., "Evoked Responses to Numerical and Non-Numerical Visual Stimuli while Problem Solving," *Nature*, vol. 203, no. 4950, pp. 1155–1157, Sep. 1964.

[46] Sutton, S., Braren, M., Zubin, J., and John, E. R., "Evoked-Potential Correlates of Stimulus Uncertainty," *Science (80-.).*, vol. 150, no. 3700, pp. 1187–1188, Nov. 1965.

[47] Donchin, E.; Ritter W.; McCallum, C., "Cognitive psychophysiology: the endogenous components of the ERP," in *Event-Related Brain Potentials in Man*, Elsevier, 1978.

[48] Linden, D. E. J., "The P300: Where in the Brain Is It Produced and What Does It Tell Us?," *Neurosci.*, vol. 11, no. 6, pp. 563–576, Dec. 2005.

[49] Bledowski, C., "Localizing P300 Generators in Visual Target and Distractor Processing: A Combined Event-Related Potential and Functional Magnetic Resonance Imaging Study," *J. Neurosci.*, vol. 24, no. 42, pp. 9353–9360, Oct. 2004.

[50] Donchin, E., "Surprise!? Surprise?," *Psychophysiology*, vol. 18, no. 5, pp. 493–513, Sep. 1981.

[51] Donchin, E. and Coles, M. G. H., "Is the P300 component a manifestation of context updating?," *Behav. Brain Sci.*, vol. 11, no. 03, p. 357, Sep. 1988.

[52] Polich, J. and Criado, J. R., "Neuropsychology and neuropharmacology of P3a and P3b,"

Int. J. Psychophysiol., vol. 60, no. 2, pp. 172–185, May 2006.

[53] Polich, J., Ellerson, P. C., and Cohen, J., "P300, stimulus intensity, modality, and probability," *Int. J. Psychophysiol.*, vol. 23, no. 1–2, pp. 55–62, Aug. 1996.

[54] Katayama, J. and Polich, J., "Auditory and visual P300 topography from a 3 stimulus paradigm," *Clin. Neurophysiol.*, vol. 110, no. 3, pp. 463–468, Mar. 1999.

[55] Comerchero, M. D. and Polich, J., "P3a and P3b from typical auditory and visual stimuli," *Clin. Neurophysiol.*, vol. 110, no. 1, pp. 24–30, Jan. 1999.

[56] Farwell, L. A. and Donchin, E., "Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials," *Electroencephalogr. Clin. Neurophysiol.*, vol. 70, no. 6, pp. 510–523, Dec. 1988.

[57] Donchin, E., Spencer, K. M., and Wijesinghe, R., "The mental prosthesis: assessing the speed of a P300-based brain-computer interface," *IEEE Trans. Rehabil. Eng.*, vol. 8, no. 2, pp. 174–179, Jun. 2000.

[58] Qu, J. *et al.*, "A Novel Three-Dimensional P300 Speller Based on Stereo Visual Stimuli," *IEEE Trans. Human-Machine Syst.*, vol. 48, no. 4, pp. 392–399, Aug. 2018.

[59] Zhang, N., Zhou, Z., Liu, Y., Yin, E., Jiang, J., and Hu, D., "A Novel Single-Character Visual BCI Paradigm With Multiple Active Cognitive Tasks," *IEEE Trans. Biomed. Eng.*, vol. 66, no. 11, pp. 3119–3128, Nov. 2019.

[60] Noorzadeh, S., Rivet, B., and Jutten, C., "3-D Interface for the P300 Speller BCI," *IEEE Trans. Human-Machine Syst.*, vol. 50, no. 6, pp. 604–612, Dec. 2020.

[61] Wolpaw, J. R. *et al.*, "Independent home use of a brain-computer interface by people with amyotrophic lateral sclerosis," *Neurology*, vol. 91, no. 3, pp. e258–e267, Jul. 2018.

[62] Brunner, P., Joshi, S., Briskin, S., Wolpaw, J. R., Bischof, H., and Schalk, G., "Does the 'P300' speller depend on eye gaze?," *J. Neural Eng.*, vol. 7, no. 5, p. 056013, Oct. 2010.

[63] Eyetracking, "What Is Eyetracking?," *About Us: What Is Eyetracking?*, 2011. [Online]. Available: http://www.eyetracking.com/About-Us/What-Is-Eye-Tracking.

[64] Sharma, R., "Oculomotor Dysfunction in Amyotrophic Lateral Sclerosis," *Arch. Neurol.*, vol. 68, no. 7, p. 857, Jul. 2011.

[65] Sellers, E. W. and Donchin, E., "A P300-based brain–computer interface: Initial tests by ALS patients," *Clin. Neurophysiol.*, vol. 117, no. 3, pp. 538–548, Mar. 2006.

[66] Halder, S. *et al.*, "An auditory oddball brain–computer interface for binary choices," *Clin. Neurophysiol.*, vol. 121, no. 4, pp. 516–523, Apr. 2010.

[67] Kaufmann, T., Holz, E. M., and Kübler, A., "Comparison of tactile, auditory, and visual

modality for brain-computer interface use: a case study with a patient in the locked-in state," *Front. Neurosci.*, vol. 7, 2013.

[68] Vlahinić, S., Batistić, L., Jadav, G. M., and Vrankić, M., "Brain Computer Interface Based Communicator for Persons in Locked-in State," *Informatica*, vol. 30, no. 4, pp. 781–798, Jan. 2019.

[69] Furdea, A. *et al.*, "An auditory oddball (P300) spelling system for brain-computer interfaces," *Psychophysiology*, vol. 46, no. 3, pp. 617–625, May 2009.

[70] Höhne, J., "A novel 9-class auditory ERP paradigm driving a predictive text entry system," *Front. Neurosci.*, vol. 5, 2011.

[71] Schreuder, M., Blankertz, B., and Tangermann, M., "A New Auditory Multi-Class Brain-Computer Interface Paradigm: Spatial Hearing as an Informative Cue," *PLoS One*, vol. 5, no. 4, p. e9813, Apr. 2010.

[72] Schreuder, M., Rost, T., and Tangermann, M., "Listen, You are Writing! Speeding up Online Spelling with a Dynamic Auditory BCI," *Front. Neurosci.*, vol. 5, 2011.

[73] Kleih, S. C., Herweg, A., Kaufmann, T., Staiger-Sälzer, P., Gerstner, N., and Kübler, A., "The WIN-speller: a new intuitive auditory brain-computer interface spelling application," *Front. Neurosci.*, vol. 9, Oct. 2015.

[74] Höhne, J. and Tangermann, M., "Towards User-Friendly Spelling with an Auditory Brain-Computer Interface: The CharStreamer Paradigm," *PLoS One*, vol. 9, no. 6, p. e98322, Jun. 2014.

[75] Fernández-Rodríguez, Á. *et al.*, "Effect of Distracting Background Speech in an Auditory Brain–Computer Interface," *Brain Sci.*, vol. 11, no. 1, p. 39, Jan. 2021.

[76] Hübner, D., Schall, A., Prange, N., and Tangermann, M., "Eyes-Closed Increases the Usability of Brain-Computer Interfaces Based on Auditory Event-Related Potentials," *Front. Hum. Neurosci.*, vol. 12, Sep. 2018.

[77] Renard, Y. *et al.*, "OpenViBE: An Open-Source Software Platform to Design, Test, and Use Brain–Computer Interfaces in Real and Virtual Environments," *Presence Teleoperators Virtual Environ.*, vol. 19, no. 1, pp. 35–53, Feb. 2010.

[78] Rivet, B., Souloumiac, A., Attina, V., and Gibert, G., "xDAWN Algorithm to Enhance Evoked Potentials: Application to Brain–Computer Interface," *IEEE Trans. Biomed. Eng.*, vol. 56, no. 8, pp. 2035–2043, Aug. 2009.

[79] Rivet, B. and Souloumiac, A., "Optimal linear spatial filters for event-related potentials based on a spatio-temporal model: Asymptotical performance analysis," *Signal*

Processing, vol. 93, no. 2, pp. 387–398, Feb. 2013.

[80] Najarian, K. and Splinter, R., "Singular Value Decomposition & Independent Component Analysis for Blind Source Separation," in *Biomedical Signal and Image Processing*, Boca Raton: CRC Press, 2016.

[81] OpenVIBE, "xDAWN Trainer," *Documentation OpenViBE*, 2022. [Online]. Available: http://openvibe.inria.fr/documentation/3.3.1/Doc_BoxAlgorithm_XDAWNTrainer.html.

[82] Ma, Y. and Guo, G., *Support Vector Machines Applications*. Cham: Springer International Publishing, 2014.

[83] Krizhevsky, A., Sutskever, I., and Hinton, G. E., "ImageNet classification with deep convolutional neural networks," *Commun. ACM*, vol. 60, no. 6, pp. 84–90, May 2017.

[84] Le Guennec, A.; Malinowski, S.; Tavenard, R., "Data Augmentation for Time Series Classification using Convolutional Neural Networks," in *ECML/PKDD Workshop on Advanced Analytics and Learning on Temporal Data*, 2016.

[85] Cecotti, H. and Graser, A., "Convolutional Neural Networks for P300 Detection with Application to Brain-Computer Interfaces," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 33, no. 3, pp. 433–445, Mar. 2011.

[86] Schirrmeister, R. T. *et al.*, "Deep learning with convolutional neural networks for EEG decoding and visualization," *Hum. Brain Mapp.*, vol. 38, no. 11, pp. 5391–5420, Nov. 2017.

[87] Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. M., Hung, C. P., and Lance, B. J., "EEGNet: a compact convolutional neural network for EEG-based brain–computer interfaces," *J. Neural Eng.*, vol. 15, no. 5, p. 056013, Oct. 2018.

[88] Srivastava, N; Hinton, G; Krizhevsky, A; Sutskever, I; Salakhutdinov, R., "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *J. Mach. Learn. Res.*, vol. 15, no. 1929–1958, 2014.

[89] Laszlo, S., Ruiz-Blondet, M., Khalifian, N., Chu, F., and Jin, Z., "A direct comparison of active and passive amplification electrodes in the same amplifier system," *J. Neurosci. Methods*, vol. 235, pp. 298–307, Sep. 2014.

[90] Emmerling, T., "actiCAP active Electrodes Walkthrough," 2017. [Online]. Available: https://pressrelease.brainproducts.com/active-electrodes-walkthrough/.

[91] Kappenman, E. S. and Luck, S. J., "The effects of electrode impedance on data quality and statistical significance in ERP recordings," *Psychophysiology*, Mar. 2010.

[92] Comon, P. and Jutten, C., *Handbook of Blind Source Separation; Independet Component Analysis and Applications*. Academic Press, 2009.

[93] Hyvarinen, A., "Fast and robust fixed-point algorithms for independent component analysis," *IEEE Trans. Neural Networks*, vol. 10, no. 3, pp. 626–634, May 1999.

[94] Delorme, A. and Makeig, S., "EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis," *J. Neurosci. Methods*, vol. 134, no. 1, pp. 9–21, Mar. 2004.

[95] Delorme, A. *et al.*, "EEGLAB, SIFT, NFT, BCILAB, and ERICA: New Tools for Advanced EEG Processing," *Comput. Intell. Neurosci.*, vol. 2011, pp. 1–12, 2011.

[96] Pion-Tonachini, L., Kreutz-Delgado, K., and Makeig, S., "ICLabel: An automated electroencephalographic independent component classifier, dataset, and website," *Neuroimage*, vol. 198, pp. 181–197, Sep. 2019.

[97] Lee, T.-W., Girolami, M., and Sejnowski, T. J., "Independent Component Analysis Using an Extended Infomax Algorithm for Mixed Subgaussian and Supergaussian Sources," *Neural Comput.*, vol. 11, no. 2, pp. 417–441, Feb. 1999.

[98] Jung, T.-P., Makeig, S., McKeown, M. J., Bell, A. J., Lee, T.-W., and Sejnowski, T. J., "Imaging brain dynamics using independent component analysis," *Proc. IEEE*, vol. 89, no. 7, pp. 1107–1122, Jul. 2001.

[99] Delorme, A., Makeig, S., Fabre-Thorpe, M., and Sejnowski, T., "From single-trial EEG to brain area dynamics," *Neurocomputing*, vol. 44–46, pp. 1057–1064, Jun. 2002.

[100] Jung, T.-P., Makeig, S., Westerfield, M., Townsend, J., Courchesne, E., and Sejnowski, T. J., "Analysis and visualization of single-trial event-related potentials," *Hum. Brain Mapp.*, vol. 14, no. 3, pp. 166–185, Nov. 2001.

[101] Delorme, A. . M. S., "EEGLAB: 9. Source analysis." [Online]. Available: https://eeglab.org/tutorials/09_source/.

[102] Oostenveld, R., Fries, P., Maris, E., and Schoffelen, J.-M., "FieldTrip: Open Source Software for Advanced Analysis of MEG, EEG, and Invasive Electrophysiological Data," *Comput. Intell. Neurosci.*, vol. 2011, pp. 1–9, 2011.

[103] Delorme, A., Palmer, J., Onton, J., Oostenveld, R., and Makeig, S., "Independent EEG Sources Are Dipolar," *PLoS One*, vol. 7, no. 2, p. e30135, Feb. 2012.

[104] Makeig, S., "Auditory event-related dynamics of the EEG spectrum and effects of exposure to tones," *Electroencephalogr. Clin. Neurophysiol.*, vol. 86, no. 4, pp. 283–293, Apr. 1993.

[105] Jensen, O. and Mazaheri, A., "Shaping Functional Architecture by Oscillatory Alpha Activity: Gating by Inhibition," *Front. Hum. Neurosci.*, vol. 4, 2010.

[106] Peterson, J. E. and Voyterk, B., "Alpha oscillations control cortical gain by modulating excitatory-inhibitory background activity," *bioRxiv*, 2017.

[107] Kropotov, D. J., *Quantitative EEG, Event-Related Potentials and Neurotherapy*. Elsevier, 2009.

[108] Makeig, S. *et al.*, "Electroencephalographic Brain Dynamics Following Manually Responded Visual Targets," *PLoS Biol.*, vol. 2, no. 6, p. e176, Jun. 2004.

Popis simbola

Latinski simboli:

Varijabla	Definicija
$\boldsymbol{X}$	EEG signal neurološke aktivnosti subjekta
$\boldsymbol{A}$	*xDAWN* matrica neurološke aktivnosti povezana s ciljanim podražajem
$\boldsymbol{D}$	*xDAWN* Toeplitz matrica s vremenskim trenutcima prezentiranja ciljanog podražaja
$\widehat{\boldsymbol{A}}$	estimacija *xDAWN* matrice s istaknutim P300 odzivom na ciljani podražaj
$\boldsymbol{U}$	*xDAWN* prostorni filter
$\widehat{\boldsymbol{S}}$	*xDAWN* estimat P300 neurološke reakcije na ciljani podražaj
$\boldsymbol{Q_x}, \boldsymbol{R_x}$	komponente QR-faktorizacije EEG mjerenja $\boldsymbol{X}$
$\boldsymbol{Q_D}, \boldsymbol{R_D}$	komponente QR-faktorizacije Toeplitz matrice $\boldsymbol{D}$
$\boldsymbol{Z}$	matrica nezavisnih komponenti primjenom analize nezavisnih komponenti
$\boldsymbol{A}$	superpozicijska matrica analize nezavisnih komponenti
a_k^j	član superpozicijske matrice $\boldsymbol{A}$ koji određuje utjecaj *j*-te nezavisne komponente za *k*-tu elektrodu EEG uređaja
$\boldsymbol{Y}$	estimat nezavisnih komponenti primjenom analize nezavisnih komponenti
$\boldsymbol{W}$	estimat superpozicijske matrice analize nezavisnih komponenti
$\bar{X}$	EEG signal neurološke aktivnosti subjekta prikazan kao slučajna varijabla
$\bar{Y}$	estimat nezavisnih komponenti primjenom analize nezavisnih komponenti prikazan kao slučajna varijabla
$\bar{Z}$	nezavisne komponente primjenom analize nezavisnih komponenti prikazane kao slučajne varijable
$J(\bar{Y})$	Negentropija, razlika gaussove i promatrane slučajne varijable s jednakom standardnom devijacijom σ
$I(\bar{Y})$	količina informacija zajednička svim slučajnim varijablama opisanim vektorom $\bar{Y}$

Grčki simboli:

Ψ	jedinstveni vektori matrice $Q_D{}^T Q_x$ primjenom SVD-a
Λ	jedinstveni vektori matrice $Q_D{}^T Q_x$ primjenom SVD-a
μ	srednja vrijednost
σ	standardna devijacija

Popis skraćenica

Skraćenica	Definicija
ALS	amiotrofična lateralna skleroza
EEG	elektroencefalogram, elektroencefalografija
LIS	locked-in syndrome, sindrom zaključane osobe
CLIS	completely Locked-in syndrome, sindrom potpuno zaključane osobe
BCI	Brain-Computer Interface, sučelje mozak-računalo
MEG	magnetoencefalografija
fMRI	funkcionalna magnetna rezonanca
fNIRS	funkcionalna bliska infracrvena spektroskopija
SMR	senzorno-motorni ritmovi
ERS	eventom evocirana sinkronizacija
ERD	eventom evocirana desinkronizacija
ERP	eventom evocirani potencijali
SSVEP	potencijal konstantne frekvencije evociran vizualnim podražajem
SPC	spori moždani potencijali
ITR	brzina prijenosa podataka
SVM	support vector machine, metoda potpornih vektora
CNN	Convolutional neural network, konvolucijska neuronska mreža
PCA	Principal component analysis, analiza osnovnih komponenti
SVD	Singular value decomposition
ICA	Independent component analysis, analiza nezavisnih komponenti
ELU	Exponential Linear Unit
EKG	elektrokardiogram
EOG	elektrookulogram
GND	Uzemljenje
REF	Referentni potencijal
STFT	Short-time Fourier transform, Fourierova transformacija s vremenskim prozorom
DLPFC	Dorsolateralani prefrontalni korteks

ROC	Receiver operating characteristic
SNR	omjer korisnog signala i pozadinskog šuma
LSE	metoda najmanje kvadratne udaljenosti
MI	Mutual information, količina zajedničke informacije dvije slučajne varijable
CGT	centralni granični teorem

Popis slika

Slika 2.1. Prikaz standardnih konfiguracija sučelja mozak-računalo. Ovisno o tipu sučelja, u prvoj varijanti (lijeva strana) računalo generira vizualne, auditorne ili taktilne stimulacije u definiranim vremenskim intervalima te na temelju izmjerene i obrađene moždane aktivnosti sinkroniziranom sa stimulacijom određuje od strane korisnika ciljanu stimulaciju. U drugoj varijanti (desna strana) korisnik sam određuje potrebu za motoričkom radnjom, nakon čega se na temelju mjerene moždane aktivnosti definiraju parametri za upravljanje elektromehaničkim sustavima. Ovisno o zahtjevima sustava moguće je odabrati jednu ili kombinaciju više metoda za mjerenje moždane aktivnosti. Preuzeto sa [11]. 8

Slika 2.2. Prikaz temporalne i prostorne rezolucije dosad predstavljenih metoda akvizicije neurološke aktivnosti. Pored već spomenutih metoda, na slici je prikazana polu-invazivna pozitronska emisijska tomografija (engl. *Positron Emission Tomography*, PET) metoda koja koristi radioaktivni marker koji se ubrizgava subjektu kao sredstvo detekcije metaboličkih procesa odnosno s time povezana neurološka aktivnost. 13

Slika 3.1. Prikaz predložene eksperimentalne paradigme kao osnove za auditorno sučelje mozak-računalo. Svako traženo slovo određeno je nizom od 22 odabrana slova hrvatske abecede koja se nasumično prezentiraju korisniku s razmakom od jedne sekunde, a čiji se ERP mjeri EEG uređajem. Crvenim okvirom u svakom segmentu označena su ciljana slova, dok visokofrekventni zvuk označava kraj trenutnog odnosno početak slijedećeg segmenta. Ispod vremenske osi nalazi se fotografija subjekta u laboratoriju tijekom provedbe eksperimenta. 24

Slika 3.2. Prikaz implementacije predložene eksperimentalne paradigme u *OpenVibe* razvojnom okuženju. 26

Slika 4.1. Prikaz Brain Products V-Amp akvizicijskog EEG uređaja korištenog u ovom doktorskom radu s 16 aktivnih elektroda pričvršćenih na prilagodljivu Acticap kapu. 36

Slika 4.2. Prikaz lokacija korištenih aktivnih mjernih elektroda (zelena boja) prema 10-20 normi uz dodatne dvije elektrode GND i REF (narančasta boja) postavljene na

mastroidne kosti iza lijevog odnosno desnog uha subjekta. Prema konfiguraciji najzastupljenije su centralna i parijetalna regija u kojima se očekuje najjači P300 odziv. 37

Slika 4.3. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti prvog subjekta lokaliziranih u temporalnoj i centralno-temporalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom. Nezavisna komponenta 9 (prvi red) locirana u temporalnoj regiji zadužena je za obradu auditornih podražaja, dok su nezavisne komponente 2 i 16 (drugi i treći red) neurološke reakcije povezane s motoričkom aktivnosti odnosno pritiskanjem tipke. 45

Slika 4.4. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti prvog subjekta lokaliziranih u frontalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom.. 47

Slika 4.5. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti prvog subjekta lokaliziranih u parijetalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom. Istaknute komponente na temelju prikazanih karakteristika gotovo sigurno pripadaju P3b odzivu na ciljanu stimulaciju. 47

Slika 4.6. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponente neurološke aktivnosti drugog subjekta lokalizirane u temporalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom. Prikazana komponenta zadužena je za obradu akustičnih podražaja. 51

Slika 4.7. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponente neurološke aktivnosti drugog subjekta lokalizirane u frontalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom.. 51

Slika 4.8. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti drugog subjekta lokaliziranih u okcipitalnoj i centalno-parijetalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom. Istaknute komponente na temelju prikazanih karakteristika gotovo sigurno pripadaju P3b odzivu na ciljanu stimulaciju i procesu pritiska tipke. 52

Slika 4.9. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponente neurološke aktivnosti drugog subjekta lokalizirane u okcipitalnoj regiji mozga primjenom predložene eksperimentalne paradigme s povratnom vezom. Dobivena komponenta primjer je alfa valova koji u okcipitalnoj regiji nastaju zbog zatvorenih očiju subjekta. 54

Slika 4.10. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti prvog subjekta lokaliziranih u frontalnoj regiji mozga primjenom predložene eksperimentalne paradigme bez povratne veze. ... 56

Slika 4.11. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti prvog subjekta lokaliziranih u parijetalnoj regiji mozga primjenom predložene eksperimentalne paradigme bez povratne veze. Istaknute komponente na temelju prikazanih karakteristika gotovo sigurno pripadaju P3b odzivu na ciljanu stimulaciju. 57

Slika 4.12. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponente neurološke aktivnosti drugog subjekta lokaliziraih u temporalnoj regiji mozga primjenom predložene eksperimentalne paradigme bez povrate veze. Prikazana komponenta zadužena je za detekciju i obradu akustičnih podražaja. . 57

Slika 4.13. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti drugog subjekta lokaliziranih u frontalnoj regiji mozga primjenom predložene eksperimentalne paradigme bez povrate veze. 58

Slika 4.14. Prikaz temporalnih, prostornih i vremensko-frekvencijskih karakteristika komponenata neurološke aktivnosti drugog subjekta lokaliziranih u okcipitalnoj i parijetalnoj regiji mozga primjenom predložene eksperimentalne paradigme bez povrate veze. 59

Slika 5.1. Rezultati treniranja i validacije klasifikacije ciljanih i ne-ciljanih stimulacija primjenom *xDAWN* prostornog filtera i SVM klasifikatora na pred-obrađenim EEG podatcima prikupljenih predloženom eksperimentalnom paradigmom bez povratne veze. 62

Slika 5.2. Rezultati treniranja i validacije klasifikacije ciljanih i ne-ciljanih stimulacija primjenom konvolucijske neuronske mreže na pred-obrađenim EEG podatcima prikupljenih primjenom predložene eksperimentalne paradigme bez povratne veze.

..... 65

Slika 5.3. Rezultati pisanja šest rečenica primjenom predloženog sučelja mozak – računalo uz primjenu xDAWN/SVM klasifikacije (lijevi stupac unutar svake rečenice) i konvolucijske neuronske mreže (desni stupac unutar istih rečenica). AVG predstavlja ostvarenu srednju vrijednost točnosti svih šest rečenica. Plavim stupcima označena je točnost sustava, ako je ciljana stimulacija odabrana na temelju maksimalne klasifikacijske vrijednosti. Crvenim stupcima definirana je vjerojatnost da se ciljana stimulacija nalazi unutar skupa od pet stimulacija sa najboljima klasifikacijskim vrijednostima. 67

Slika 5.4. Predložena arhitektura BCI sustava za pisanje u dvije klasifikacijske razine. 71

Slika 5.5. Rezultati točnosti kod pisanja rečenica za svih deset subjekata primjenom *xDAWN* i SVM klasifikatora (prva dva stupca u svakoj rečenici) odnosno CNN klasifikatora (posljednja dva stupca u rečenici). Plavom bojom označena je konačna točnost sustava nakon prve klasifikacijske faze, dok je žutom prikazana konačna točnost sustava nakon druge klasifikacije faze. Kao i u prethodnom poglavlju crvenom bojom označena je vjerojatnost da se ciljana stimulacija nakon prve klasifikacijske razine nalazi u skupu pet stimulacija s najvišim klasifikacijskim vrijednostima.. 73

Slika 5.6. Prikaz reduciranih konfiguracija elektroda korištenih u analizi točnosti sustava. (a) prva reducirana konfiguracija bez okcipitalnih elektroda; (b) druga reducirana konfiguracija; (c) treća reducirana konfiguracija bez okcipitalnih i centralnih elektroda; (d) četvrta reducirana konfiguracija elektroda. 78

Slika 5.7. Rezultati treniranja klasifikatora s reduciranim konfiguracijama EEG elektroda prikazani u obliku ROC krivulja. Kod prvog do četvrtog subjekta korištena je CNN metoda dok je kod desetog subjekta korišten *xDAWN* prostorni filter u kombinaciji sa SVM klasifikatorom. 79

Slika 5.8. Rezultati točnosti pisanja rečenica pomoću predloženog sučelja s dvije klasifikacijske razine. Za svakog od prikazanih subjekata novi klasifikatori učeni su na reduciranim setovima podataka određenim konfiguracijom elektroda. Svaka rečenica klasificirana je pomoću klasifikatora prilagođenih predloženim konfiguracijama elektroda, a točnost klasifikacije slova određena je stupcima različitih boja; plava: kompletna konfiguracija elektroda s 16 aktivnih elektroda;

crvena: prva reducirana konfiguracija s 13 aktivnih elektroda; žuta: druga reducirana konfiguracija s 11 aktivnih elektroda; ljubičasta: treća reducirana konfiguracija s 8 aktivnih elektroda; zelena: četvrta reducirana konfiguracija s 5 aktivnih elektroda. Posljednja grupa stupaca predstavlja ostvarenu srednju vrijednost po svim rečenicama za svaku od prezentiranih konfiguracija elektroda. 81

Slika 6.1. Izvedba BCI sustava za pisanje u *OpenVibe* razvojnom okruženju. *Generate Stimulation* i *Signal Processing* blokovi pozivaju MATLAB .m funkcije odgovorne za generiranje stimulacija, te akviziciju, pred-obradu i klasificiranje mjerenih EEG signala. 84

Slika 6.2. Prikaz arhitekture predloženog BCI sustava za pisanje primjenom auditornih podražaja u stvarnom vremenu. Nakon visokofrekventnog zvuka za početak segmenta, pauza od jedne sekunde omogućava korisniku pripremu na prvo slovo stimulacijskog niza. Ovisno o klasifikacijskim rezultatima u prvoj razini, moguće je preskakanje druge klasifikacijske razine, te direktan prelazak na krajnju sekvencu visokofrekventni zvuk – ciljano slovo, čime je segment definiran vremenski intervalom od cca. 28s odnosno cca. 40s u slučaju dvije klasifikacijske razine. U slučaju odabira mogućnosti povratka na prethodno slovo, prva klasifikacijska razina je proširena za dodatnu simulaciju čime je ukupno trajanje segmenta produženo za jednu sekundu. Okviri crvene boje označavaju ciljanu stimulaciju/slovo. 85

Slika 6.3. Prikaz parametara *Generate Stimulation* bloka za koordiniranje sustava i generiranje niza auditornih stimulacija. 86

Slika 6.4. Prikaz parametara *Signal Processing* bloka za prikupljanje, obradu i klasifikaciju EEG signala neurološke aktivnosti. 87

Popis tablica

Tablica 3.1. Popis svih stimulacija i markera korištenih u predloženoj eksperimentalnoj paradigmi zajedno s pridruženim *OpenVibe* nazivima i jedinstvenom identifikacijskom numeričkim vrijednostima. 28

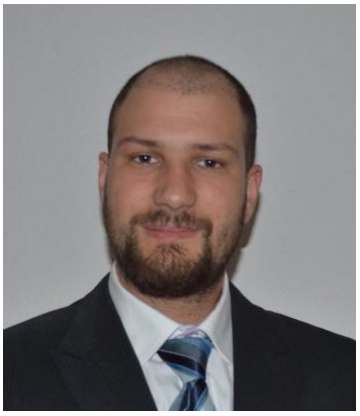
Tablica 5.1. Ostvarene *ITR* vrijednosti za sve rečenice i sve subjekte korištenjem obje predložene klasifikacijske metode. 70

Tablica 5.2 Prikaz rezultata ostvarenih primjenom predloženog BCI sustava za pisanje u dvije klasifikacijske razine. Pored točnosti prikazane su i ostvarene *ITR* vrijednosti nakon obje klasifikacijske razine kao i ostvarena poboljšanja primjenom druge klasifikacijske razine. 76

Tablica 6.1. Ostvareni rezultati pisanja rečenica primjenom predloženog BCI sustava u stvarnom vremenu za svako slovo pisane rečenice. Zelenom bojom označena su točno klasificirana slova, dok su žutom bojom označena također točno klasificirana slova, ali s pomaknutim redoslijedom uslijed gubitka koncentracije subjekta. U stupcu „Broj slova 1. faza“ prikazan je broj slova unutar rečenice kod kojih je izostavljena druga klasifikacijska razina. 90

Tablica 6.2. Prikaz rezultata pisanja riječi primjenom predloženog BCI sustava uz mogućnost korekcije krivo odabranog slova za sva slova pisane rečenice. Zelenom bojom označena su točno odabrana slova ili naredba POVRATAK. Korekcija prethodnog slova od strane subjekta označen je desnom strelicom i prelaskom u novi red. ... 94

Životopis



Ivan Markovinović rođen je 1987. godine u Rijeci. Nakon završetka osnovne škole 2002. godine, upisuje matematički smjer u Gimnaziji Andrija Mohorovičić, Rijeka. Završetkom srednjoškolskog obrazovanja 2006. godine, upisuje Fakultet elektrotehnike i računarstva, Sveučilišta u Zagrebu na kojem je 2011. godine diplomirao s radom upravljanja četveronožnog robota. Sljedeće godine zapošljava se kao razvojni inženjer u IAV GmbH, Njemačka gdje sudjeluje u koordinaciji razvoja i testiranja upravljačkih algoritama dizel motora osobnih automobila marke Audi. Nakon dvije godine, mijenja radno mjesto unutar iste kompanije i zapošljava se kao razvojni inženjer sustava za upravljanje longitudinalnim ubrzanjem automobila, s zadatkom razvoja i testiranja regulatora akceleracije. Povratkom u Hrvatsku 2017. godine zapošljava se kao asistent na Zavodu za automatiku i elektroniku Tehničkog fakulteta Sveučilišta u Rijeci, gdje sudjeluje u izvođenju nastave na kolegijima: Mjerenja u elektrotehnici, Elektronika, Elektronika II, Automatizirana instrumentacija. Iste godine započinje svoj doktorski studij pod vodstvom prof. Vlahinića i komentora prof. Vrankića. Tijekom studija provodi tri mjeseca na Fakultetu za matematiku, prirodne znanosti i informacijske tehnologija, Sveučilišta u Kopru (Fakulteta za matematiko, naravoslovje in informacijske tehnologije), te objavljuje pet znanstvenih članaka i sudjeluje na tri znanstvene konferencije.

Lista publikacija

Izvorni znanstveni članci:

1. Markovinović, I., Vrankić, M., Vlahinić, S., and Šverko, Z., “Design considerations for the auditory brain computer interface speller”, *Biomed. Signal Process. Control*, vol. 75, p. 103546, May 2022.
2. Markovinović, I., Vrankić, M., and Vlahinić, S., “Removal of eye-blink artifacts from EEG signal”, *Eng. Rev.*, vol. 40, no. 2, pp. 101–111, Apr. 2020.
3. Šverko, Z., Stojković, N., Vlahinić, S., and Markovinović, I., “Noise and sensitivity comparison for different BP filter designs”, *Automatika*, vol. 62, no. 3–4, pp. 319–330, Oct. 2021.
4. Šverko, Z., Markovinović, I., Vrankić, M., and Vlahinić, S., “EEG data processing in ADHD diagnosis and neurofeedback”, *Eng. Rev.*, vol. 40, no. 3, pp. 116–123, May 2020.
5. Vrankic, M., Vlahinić, S., Šverko, Z., and Markovinović, I., “EEG-Validated Photobiomodulation Treatment of Dementia—Case Study”, *Sensors*, vol. 22, no. 19, p. 7555, Oct. 2022.

Konferencije:

1. Markovinovic, I., “Blind source separation”, in *2nd Conference on Machine Learning for Gravitational Waves, Geophysics and Control Systems + 3rd g2net MC Meeting*, 2019.
2. Sverko, Z., Stojkovic, N., Vlahinic, S., and Markovinovic, I., “Noise improvement for different BP filter designs”, in *2019 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, 2019, pp. 122–127.
3. Sverko, Z., Vlahinic, S., Vrankic, M., and Markovinovic, I., “Delta/Alpha Ratio for Diagnosis of Autism Spectrum Disorder”, in *2020 43rd International Convention on Information, Communication and Electronic Technology (MIPRO)*, 2020, pp. 158–162.