

**SVEUČILIŠTE U SPLITU
FAKULTET ELEKTROTEHNIKE, STROJARSTVA I
BRODOGRADNJE**

**POSLIJEDIPLOMSKI DOKTORSKI STUDIJ
ELEKTROTEHNIKE I INFORMACIJSKE TEHNOLOGIJE**

KVALIFIKACIJSKI ISPIT

**KLASIFIKACIJA SLIKOVNIH
VREMENSKIH SERIJA EEG SIGNALA PRI
RJEŠAVANJU MENTALNIH ZADATAKA**

Pero Bogunović

Split, srpanj 2021.

SADRŽAJ

1. UVOD.....	1
2. METODE PRIKUPLJANJA SIGNALA.....	3
2.1 Elektroencefalografija.....	3
2.1.1 EEG Signal.....	4
2.1.2 Artefakti u EEG signalu.....	7
2.2 Magnetoencefalografija.....	9
2.3 Funkcionalna magnetska rezonancija.....	11
2.4 Magnetoencefalografija (MEG) u odnosu na Elektroencefalografiju (EEG).....	12
3. SUČELJA MOZGA I RAČUNALA POMOĆU STROJNOG UČENJA.....	15
3.1 Strojno učenje.....	15
3.1.1 Prekomjerno prilagođavanje.....	16
3.1.2 Strojno učenje za sučelja mozga i računala.....	18
3.1.3 Linearna diskriminantna analiza.....	19
4. KLASIFIKACIJSKI ALGORITMI.....	22
4.1 Prilagodljivi klasifikatori.....	22
4.2 Klasifikacija EEG matrica i tenzora.....	23
4.3 Prijenosno učenje.....	25
4.4 Duboko učenje.....	27
5. RAČUNALNO MODELIRANJE I PRIRODNA INTELIGENCIJA.....	30
5.1 Vjerojatnosti pristup pri modeliranju kognitivne arhitekture.....	31
5.2 Računalno modeliranje kognitivnih procesa.....	32
5.2.1 Učenje.....	32
5.2.2 Spoznavanje.....	34
5.2.3 Pamćenje.....	35
5.2.4 Izvođenje.....	36
5.2.5 Procjenjivanje.....	37
5.2.6 Rasuđivanje.....	39
6. KLASIFIKACIJA SLIKOVNIH VREMENSKIH SERIJA EEG SIGNALA PRI RJEŠAVANJU MENTALNIH ZADATAKA.....	40
6.1 Uvod.....	40
6.2 Opis sustava.....	42
6.3 Eksperimentalna faza.....	44
6.4 Metodologija.....	45

6.5 Opis	46
6.6 Pretprocesiranje signala	48
6.7 Ekstrakcija signala	48
6.8 Gramiano polje kutne razlike (GADF)	49
6.9 Model	50
6.10 Rezultati	53
7. ZAKLJUČAK	59
LITERATURA.....	60
POPIS OZNAKA I KRATICA.....	75

1. UVOD

Sučelje mozak-računalo BCI (eng. Brain computer interface) pruža način za razvoj interakcije između mozga i računala. Komunikacija se razvija kao rezultat neuronskih odgovora generiranih u mozgu uslijed motoričkih pokreta ili kognitivnih aktivnosti. Te radnje generiraju moždane aktivnosti ili moždane valove koji se usmjeravaju na hardverski uređaj radi izvođenja određenih zadataka. BCI je u početku razvijen kao komunikacijski uređaj za pacijente koji pate od neuromuskularnih poremećaja. Zahvaljujući nedavnom napretku BCI uređaja poput pasivnih elektroda, bežičnih slušalica, prilagodljivom softveru i smanjenim troškovima omogućeno je i korištenje BCI tehnologije i za širu javnost. BCI uređaj bilježi reakcije mozga pomoću različitih invazivnih i neinvazivnih tehnologija poput elektrokortikografije (ECoG), elektroencefalografije (EEG), magnetoencefalografije (MEG) i magnetske rezonancije (MRI). Odgovor mozga treba prevesti pomoću strojnog učenja i aplikacije za prepoznavanja uzoraka. Ljudski mozak je najveći (oko 3 kilograma) i najsloženiji među svim ljudskim organima, koji se sastoji od milijardi neurona. To je višeprocorski sustav koji prima informacije iz osjetnih organa, obrađuje informacije i u skladu s tim kontrolira naše postupke. Ljudski mozak ima složenu strukturu neusporedivog proračunskog kapaciteta, uključujući sposobnost višeprocorsiranja i učenja, stoga je oduvijek privlačio znanstvenike od ranog doba. Razne su nove paradigme poput neuroznanosti, umjetne inteligencije, kognitivne znanosti i sučelja mozak-računalo BCI koncipirane tako kako bi se dublje razumjelo mozak. Inspiracija za razvojem BCI tehnologije potiče od potrebe za pružanjem socijalne pomoći osobama koje pate od nekih neuromuskularnih smetnji.


BCI je sustav koji prevodi misli i omogućuje sučelje za komunikaciju s vanjskim svijetom. Nedavni napredak u BCI-u omogućio je razumijevanje funkcija i neuronske komunikacije unutar mozga. Proučavanje mozga pomoglo je ne samo istraživačima na medicinskom polju već i na polju inženjerstva. Uz snimanje i prikaz moždane aktivnosti, BCI omogućuje korisniku upravljanje programima poput video igara, računalnog softvera, pravopisa [1], [2], web preglednika [3] i uređaja za prevođenje eeg signala [4].

Široko je područje studija i zahtijeva znanje informatike, inženjerstva, neuroznanosti, psihologije i obrade signala. Tipični BCI sustav uključuje sustav za prikupljanje signala, tehnike obrade signala i izlazni uređaj, kao što je prikazano na *slici 1.1*.

Prikupljanje signala može se izvesti na tri načina: invazivni, neinvazivni i poluinvasivni. Invazivne tehnike uključuju akviziciju signala prodornim mikroelektrodama u moždanu

ovojnicu mozga. U poluinvazivnim pristupima elektrode su smještene ispod vlasišta, ali ne u sivoj tvari. Neinvazivne tehnike uključuju postavljanje elektrode na tjemenu bez operacije. Neke od neinvazivnih tehnika koje se koriste za bilježenje moždanih signala su elektroencefalografija EEG, magnetoencefalografija MEG i magnetska rezonancija MRI. Neinvazivne tehnike opsežno se koriste za istraživanje, jer te tehnike nisu sklone oštećenju moždanih tkiva. Moždani signali snimljeni uređajima za prikupljanje signala obrađuju se, pojačavaju i pretvaraju u oblike prepoznatljive ljudima pomoću pojačala i pretvarača. Obrada signala uključuje filtriranje, izdvajanje značajki i klasifikaciju moždanih potencijala ili moždanih signala. Neobrađeni podaci o mozgu uglavnom su kontaminirani motorno-mišićnim artefaktima te je glavni zadatak koji preostaje znanstvenicima i istraživačima uklanjanje onečišćenja i izdvajanje korisnih podataka. Ekstrakcija značajki uključuje uklanjanje šuma i artefakata kako bi se dobili čisti, nekontaminirani podaci koji se mogu koristiti za razvoj BCI aplikacije.

Dostupni su različiti algoritmi za izdvajanje značajki (poznati i kao transformacija obilježja) za pretvaranje izvornih podataka u određeni vektor značajke, poput neovisne analize komponenta ICA [5], zajedničkih prostornih uzoraka CSP [6], analize glavne komponente PCA [7] i wavelet transformacije WT [8]. Odabrani vektori obilježja klasificirani su u željene klase primjenom klasifikacijskih algoritama poput linearne diskriminantne analize LDA [9] stroja potpornih vektora SVM [10], neuronske mreže NN [11], neizrazite (fuzzy) logike FIS [12] i mnogih drugih.




Slika 1.1. Sučelje mozak-računalo

2. METODE PRIKUPLJANJA SIGNALA


2.1 Elektroencefalografija

Klinička elektroencefalografija jedna je od nekoliko metoda prikupljanja podataka iz ljudskog mozga. Metodu je uveo Hans Berger, njemački psihijatar 1930-ih [13]. To je neinvazivna metoda koja se sastoji u otkrivanju i registraciji električne aktivnosti mozga pomoću elektroda pričvršćenih za vlasište koje registriraju promjene električnog potencijala na površini kože a koje proizlaze iz aktivnosti cerebralnih neurona [14] i nakon njihovog pojačanja čine zapis - encefalogram.

EEG nudi visoku vremensku rezoluciju koja nije moguća s MRI. Ostvarivanje otpora elektrode ne veće od 10Ω na samom početku istraživanja je bitan uvjet za dobivanje kvalitetnog EEG-a. To je najčešće korištena neinvazivna tehnika za stjecanje električne aktivnosti koju generiraju moždane stanice (neuroni ili živčane stanice i glija stanice). Signali se snimaju postavljanjem metalnih elektroda na vlasište. Metalne elektrode uglavnom su izrađene od njemačkog srebra, koji je legura bakra, nikla i cinka. Politetrafluoretilen (teflon) koristi se za oblaganje žica i metalnih elektroda. Na elektrode na vlasištu nanosi se elektrolitni gel ili pasta kako bi se pokrenula vodljivost između njih. Pasta se sastoji od iona lanolina i klorida, što pomaže u električnoj vodljivosti. Elektrode se postavljaju na tjeme mozga pomoću standardnog sustava za postavljanje elektroda 10-20. Uz to, postoje 10-10 i 10-5 sustavi za postavljanje elektroda za prikupljanje signala. Protokol za postavljanje elektroda 10-10 se u posljednje vrijeme intenzivno koristi jer pruža detaljnije moždane signale. Slika 2.1 prikazuje 10-20 i 10-10 sustave elektroda.



10-20 SUSTAV ELEKTRODA



10-10 SUSTAV ELEKTRODA



Slika 2.1. 10-20 i 10-10 sustavi elektroda

2.1.1 EEG Signal

EEG signal je snimka električne aktivnosti mozga koja mjeri potencijal polja u prostoru oko neurona. Što je populacija neurona više sinkronizirana, to je lakše izmjeriti EEG signal. Ovaj signal nema konstantnu amplitudu i frekvenciju, valni oblik nikada nije jednostavan harmonijski signal. EEG signal karakterističan je za visoku vremensku aktivnost od oko 1 ms [15]. U ovom signalu možemo odvojiti nekoliko vrsta aktivnosti koje su karakteristične za određene frekvencije i amplitude signala kao što su: Alfa, Beta, Delta, Gamma, Theta, Lambda i Mu. Istraživanje je pokazalo da i frekvencija moždanih valova i njihova amplituda nisu strogo stalni i strogo ovise o aktivnosti koju mozak obavlja. Piramidalne stanice moždane kore zbog svog karakterističnog smještaja u strukturi moždane kore smatraju se glavnim izvorom elektroencefalografskog signala u ljudskom mozgu [16], [17].

Alfa valovi se javljaju u frekvencijskom opsegu od 8–12 Hz, a karakterizira ih amplituda u prosjeku od 3 do oko 50 μV . Aktivnost ovih valova raste kada ležimo zatvorenih očiju prije nego što zaspimo. Alfa aktivnost prisutna je kada je osoba u mirovanju, u opuštenom stanju, meditirajući itd. Ti valovi nestaju tijekom povećanog mentalnog napora, na primjer, kada testirana osoba izvršava složene matematičke zadatke.

Jedna od vrsta moždane aktivnosti su i Beta valovi s frekvencijskim rasponom od između 12 i oko 28 Hz, a njihova karakteristika je mala amplituda signala. Elektroencelografski signal s aktivnošću beta valova pokazuje značajke desinkronizacije. Beta valovi se mogu podijeliti na: SMR - senzomotorni ritam u opsegu od 13–15 Hz; Niski beta valovi - ritam je koji odgovara pravilnoj dinamici procesa uzbuđenja, dominira u lijevoj strani mozga; Visoki beta valovi - pojas iznad 18 Hz, povezan s hiperaktivnošću nervnih procesa. Potvrđeno je da beta valovi karakteriziraju normalno buđenje svijesti, sastoji se u primanju podražaja iz okoline koji uključuju sljedeća osjetila: sluh, vid, okus, dodir i miris. Bijes, strah, iznenađenje su neka od stanja koja su karakteristična za stanja koja se javljaju tijekom aktivnosti beta valova. Amplituda beta valova obično ne prelazi 20 μV .


Theta valovi su valovi s frekvencijskim rasponom od 4–7 Hz koji se mogu promatrati posebno tijekom intenzivnih emocija. Karakteristični su za procese duboke meditacije. Theta valovi mogu se podijeliti u dvije razine: Low Theta – ritam, aktivnosti u opsegu od 4 do 5,5 Hz i High Theta - ritam u rasponu od 5,5 do 7 Hz. Ovaj je ritam izravno povezan s električnom aktivnošću hipokampusa i njegova amplituda signala je velika, vrijednosti do 100 μV . Najniža primijećena vrijednost Theta vala je oko 30 μV . Ako su Theta valovi registrirani samo na jednom mjestu ili ako dominiraju samo jednom hemisferom, vrlo vjerojatno ukazuje na strukturalna oštećenja. Aktivnost theta valova mijenja se kako starimo.

Delta valovi s frekvencijskim rasponom 1–3 Hz velike su amplitude signala u rasponu od 100 do 200 μV . Njihova najviša aktivnost javlja se tijekom dubokog sna. Delta valovi, tijekom spavanja ispitane osobe, izmjenjuju se s pražnjenjima koja se sastoje od Alfa valova. Karakteristična značajka ovih valova je da se oni ne javljaju u normalnom EEG zapisu pri snimanju odrasle osobe koja je budna. Njihova prisutnost uvijek ukazuje na disfunkciju mozga. Javljaju se samo kod starijih ljudi, ali u malom broju.


Gamma valovi se opažaju u rasponu od 30 do 200 Hz. Pažljivim proučavanjem literature možemo pronaći i valove u rasponu do 500 Hz. Amplituda tih valova je unutar 3–55 μV . Brojna istraživanja pokazuju da se amplituda tih valova povećava ako se ispitana osoba koncentrira na izvor podražaja. Vrijeme trajanja gamma vala vrlo je kratka i sadrži nekoliko desetaka ms.

Mu valovi, koji se nazivaju i ritmom prolaznika, fiziološki su fenomen. Registrirani su iz središnjih vodova do motornog korteksa. Oni su dobro definirani, pojavljuju se u naletima od 7-11 Hz i nalikuju grčkom slovo μ . Mu aktivnost se ponekad jasnije pokazuje tijekom pospanosti i kod snimanja ispitanika otvorenim očiju. Mu se smanjuje pokretima gornjih udova, na primjer tijekom stezanja šaka ili čak razmišljanja o ovoj akciji.


Lambda valovi su prijelazni elektropozitivni potencijali u okcipitalnim predjelima i mogu se zamijeniti s epileptičkim potencijalima. Priziva ih vizualno skeniranje slike. Vjerojatno su to vizualni potencijali koji su evocirani [18]. Glavna prednost upoznavanja lambda valova je spoznaja da su oni fiziološki fenomen, a ne epileptiformni iscjedci. Slike 2.2 do 2.4 prikazuju različite eeg valove koji su zabilježeni od zdravog subjekta u prikladnom okruženju, u normalnim uvjetima aktivnosti.



Slika.2.2. Alpha val



Slika.2.3. Beta val



Slika.2.4. Gamma val

Trenutno su dostupni različiti uređaji za snimanje *EEG* signala u medicinske i istraživačke svrhe. Neki od komercijalno dostupnih uređaja su *NeuroSky*, *Neuroscan*, *Emotiv Epoc* i *Brain products*. Pregled značajki različitih EEG uređaja dali su Ramadan [19]. Trenutno istraživači pokušavaju razviti EEG uređaje koji su pouzdani i pružaju kvalitetne signale. Raymundo Cassani i suradnici razvili su EEG sustav niske gustoće sa 7 kanala zasnovan na automatiziranom uklanjanju artefakata za pacijente s Alzheimerom. EEG aktivnost bolesnika s Alzheimerom razlikuje se od EEG aktivnosti zdrave osobe. EEG signali bolesnika s Alzheimerom spori su zbog gubitka sinaptičkih veza i smanjene sinkronizacije između kortikalnih regija.

Većina dostupnih EEG uređaja su uređaji visoke gustoće (velik broj elektroda), poput 32-kanalnih ili 64-kanalnih EEG sustava. Zbog velikog broja elektroda, pacijenti s moždanim poremećajem mogu se osjećati nelagodno, pospano i mogu se znojiti, što rezultira lošom kvalitetom signala s artefaktima. Da bi se prevladala ta ograničenja, autori rada [20] razvili su 7-kanalni sustav niske gustoće i jednostavan za upotrebu. U drugom radu autori [21] razvili su pametnu nosivu kacigu koja prati EEG i EKG aktivnost. Također EEG signali zabilježeni su postavljanjem elektrode u ušni kanal s uređajem za nošenje. Stoga je nazvan *EarEEG*.

2.1.2 Artefakti u EEG signalu

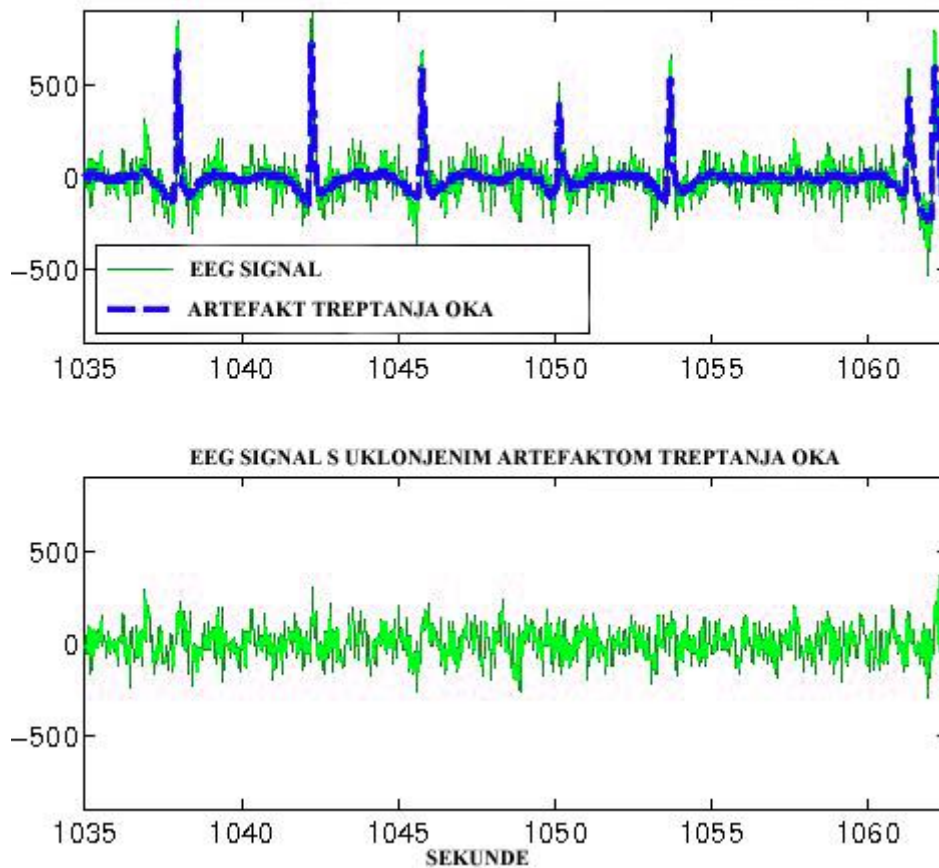
Artefakti se javljaju u EEG signalu ako nije proporcionalan električnom potencijalu koji generira mozak. Oni iskrivljuju stvarni tok moždanih valova. Artefakti se mogu klasificirati ovisno o njihovom podrijetlu kao tehnički i biološki artefakti. Utjecaj izvora artefakata izravno je proporcionalan amplitudi generiranog signala i obrnuto proporcionalan udaljenosti između izvora i EEG elektroda. Također promjene vodljivosti između elektroda i mozga treba prepoznati kao artefakte. Tehnički se artefakti uklanjaju iz EEG signala pomoću niskopropusnog filtra. Izvori tehničkih artefakata, između ostalog, su: opskrba električnom energijom, medicinski uređaji i radne stanice itd. Biološki artefakti potječu od: pokreta očnih jabučica, pokreta skeletnih mišića, pokreta tijela u odnosu na elektrode (drhtanje glave), otkucaja srca, arterijske pulsacije, znojenja, lučenja sebuma na koži, stezanja zuba, gutanja. Općenito, izvor bioloških artefakata su svi organi u organizmu, osim mozga i tkiva. Pretpostavlja se da će pokret očne jabučice prouzročiti artefakte najveće amplitude, tj. artefakte koji u najvećoj mjeri zaklanjaju sliku moždanih valova. Štoviše, u elektroencefalografskom signalnom artefaktu javljaju se impulsi uzrokovani stimulacijom mišića čiji se spektar preklapa

sa spektrom same moždane aktivnosti i na taj način otežava njihovo uklanjanje. Otkucaji srca mogu se ukloniti odabirom odgovarajućih referentnih elektroda koje omogućuju mjerenje razlike potencijala u mozgu. Psihološko stanje ispitanice osobe također izravno utječe na kvalitetu EEG signala, uključujući biološke artefakte koji se mogu pojaviti u ovom signalu. Eliminacija artefakata može se provesti likvidacijom izvora smetnji iz kojeg potječu.

Što se preciznije može okarakterizirati izvor smetnji, to se bolje mogu ukloniti smetnje iz mjerenja. Ako je nemoguće odvojiti izvor smetnji ili odsjeći kanal širenja smetnji, jedino što se može učiniti je obrada snimljenog encefalograma.

Pojasno propusna filtracija je najlakša i najčešća korištena metoda uklanjanja smetnji. Ova se filtracija sastoji u suzbijanju svih frekvencija, osim opsega korisnog signala. Uobičajeni uskopojasni filter izbacuje iz prekodiranja komponente veće od 50 Hz. Kada je nemoguće filtrirati smetnje i dobiti neiskrivljeni zapis moždanih valova, potrebno je isključiti sve segmente snimke u kojima se sumnja na artefakte.

Otkrivanje artefakata relativno velike amplitude u usporedbi s EEG zapisom nije teško ni vizualnom metodom ni automatskom analizom. Postoje algoritmi analize za otkrivanje određenih vrsta artefakata, npr. koji dolazi od pokreta očne jabučice. Takva pretraživanja rezultiraju uklanjanjem segmenata sa smetnjama a kada je priroda zaključaka dobro poznata, moguće je oporaviti pravi zapis. Pronalaženja smetnji relativno malih vrijednosti amplitude je dosta teže. Moguće je utvrditi pojavu artefakata samo na temelju spektralne ili topografske analize. Kao što proizlazi iz provedene analize kod primjera kretanje očne jabučice gdje je najveći utjecaj na potencijale frontalnih elektroda, kretanje mišića skeleta očituje se u obliku smetnji na bočnim vodovima. Artefakti uzrokovani pomicanjem elektrode u odnosu na tijelo uzrokuju smetnje samo u jednom kanalu za registraciju, stoga ih je vrlo lako uočiti. Eliminacija vanjskih artefakata nije veliki problem. Mnogo je teže eliminirati biološke (fiziološke i mišićne) artefakte. *Slika 2.5.* prikazuje MWF (modifikacija Wenzove formule) izlazni signal (plava isprekidana linija), za koji se smatra da je dobra procjena artefakata treptanja oka [22].




Slika. 2.5. Procjena artefakta treptanja oka s MWF algoritmom

2.2 Magnetoencefalografija

Magnetoencefalografija (MEG) bilježi magnetska polja nastala kao rezultat neuronske aktivnosti generirane kao odgovor na podražaj. Kao i EEG tako i MEG također bilježi postsinaptičke potencijale koje generiraju neuroni, ali u obliku magnetskih polja. MEG pruža dobru prostorno-vremensku razlučivost i nije ozbiljno onečišćena pod utjecajem artefakata mišića [23]. MEG se temelji na superprovodljivim interferencijskim uređajima (SQUID), koji su predstavljani 1960-ih. SQUID se pune velikim jedinicama tekućeg helija koje održavaju temperaturu sustava na približno $-269\text{ }^{\circ}\text{C}$. Temperatura se održava niskom kako bi se postigla niska impedancija. SQUID uređaja za otkrivanjem i pojačavanjem magnetskog polja kod generirane neuronske aktivnosti. MEG je prvi upotrijebio David Cohen [24] za mjerenje α -moždanih valova zdravog subjekta i epileptičnog bolesnika. Ograničenje upotrebe uređaja temeljenih na SQUID-u je da se moraju održavati na vrlo niskoj temperaturi, za što je potrebna

toplinska izolacija. Polagana promjena temperature tekućeg helija utjecat će na sustav i generirat će velike troškove održavanja. MEG ne treba nikakvo referenciranje, jer pruža bolju prostornu rezoluciju i manje je izobličena električnom aktivnošću tkiva. MEG se o nedavno koristi i za klinička i neurološka istraživanja. Ali, zbog troškova, ovaj uređaj nije previše popularan. Hubert Cecotti i suradnici. [25] koristili su MEG tehniku za otkrivanje moždanih signala i primijenili Bayesovu linearnu diskriminacijsku analizu (BLDA) na ulazu nakon prostornog filtriranja. Razliku između funkcioniranja autističnog mozga i normalnog ljudskog mozga zabilježili su pomoću MEG-a autori [26]. Također, koristeći MEG aktivnost, istraživači su zabilježili razlike između govora neke dvojezične i jednojezične novorođenčadi stare 11 mjeseci [27]. Ford i suradnici. [28] primijenili su statističku analizu na prostorno-vremenskim podacima zabilježenim pomoću MEG-a. Oni su ispitanicima dali slušne podražaje i otkrili razliku u kontinuiranim MEG podacima za ponovljene i nove podražaje. Primijećeno je da je za nove podražaje kortikalna aktivnost veća od aktivnosti ponovljenih podražaja. MEG polja prolaze kroz glavu bez ikakvih izobličenja. U odnosu na EEG, MEG pruža visoku prostornu i vremensku rezoluciju, prikazano na slici 2.6.



Slika 2.6. Snimanje magnetskim izvorom

Magnetoenceleografija (MEG) bavi se registracijom magnetskog polja koje stvara mozak. Omogućuje dobivanje signala mnogo veće prostorne razlučivosti od EEG-a i također bolju analizu u mnogo širem frekvencijskom rasponu. MEG signal mnogo je osjetljiviji na aktivnost populacije neurona paralelno nego okomito na vlasništvo. Prema Maxwellovim jednadžbama, svaka električna struja generira okomito orijentirano magnetsko polje i to je jakost polja koja se mjeri sensorima. Teškoće s mjerenjem magnetskih polja mozga povezane su s odvajanjem polja koja dolaze iz mozga od elektromagnetskog šuma. Magnetska polja koja nastaju

pomicanjem metalnih odvijača na udaljenosti od nekoliko metara ili automobil koji prolazi na nekoliko desetaka metara, magnetska su polja nekoliko redova snažnija od polja koja dolaze iz mozga. Stoga mjerenje MEG mora biti snimljeno u posebno dizajniranim zaštićenim sobama. Međutim, informacije koje nose energetske promjene ovog signala adekvatne su informacijama koje izvodimo iz valnih oblika EEG signala. MEG se koristi u znanstvenim istraživanjima čiji je cilj utvrditi funkcije pojedinih područja mozga; u kliničkoj dijagnostici i kao ispitivanje provedeno tijekom neurokirurških operacija radi lokalizacije patoloških regija. Nadalje, korisna je i u terapijskoj metodi praćenja električne aktivnosti mozga (eng. neurofeedback).

2.3 Funkcionalna magnetska rezonancija

fMRI je također neinvazivna tehnika koja identificira promjene u protoku kisika u krvi ili ovisno o razini kisika u krvi, Bold [29]. EEG i MEG bilježe brze promjene kortikalne aktivnosti mozga. To odražava kontinuiranu obradu signala u mozgu. fMRI neizravno mjeri aktivnost neurona mjerenjem protoka kisika u krvi. Tijekom bilo koje neuronske aktivnosti, kisik u krvi počinje teći prema deoksigeniranom području i fMRI bilježi razliku u magnetskim svojstvima generiranim protokom kisika. Tipični MRI sustav vrši analizu slika nakon skeniranja, dok fMRI u stvarnom vremenu provodi simultanu analizu. Ova značajka fMRI-a je korisna kod BCI-a za vizualizaciju moždanih aktivnosti.

fMRI koristi Echo Planar Imaging (EPI) za dobivanje mozga podjeljenog na segmente. fMRI-BCI u stvarnom vremenu daje bolje rezultate zbog svoje jakosti magnetskog polja, dobre prostorne i vremenske rezolucije, boljeg vremena odjeka i dobre homogenosti magnetskog polja [30]. Autori [31] se proučavali funkcioniranje mozga pojedinaca u različitim dobnim skupinama te su pronašli sličnosti i različitosti između funkcionalnosti njihovih mozgova pomoću fMRI-a. U studiji [32], [33], fMRI je proveden na nedonoščadi. Korišten je za ranu prognozu ozljede mozga i neuralnog razvoja. U drugom je radu razvijen novi okvir za poboljšanje točnosti otkrivanja fMRI [34]. Da bi se povećala brzina otkrivanja, izvodila se ekstrakcija signala pretvaranjem velikog volumena mozga u dijelove specifične za podražaj. Daljnje razlaganje volumena mozga izvedeno je u određeno vrijeme u odnosu na podražaj. Statistička analiza je primijenjena na svakom vremenskom odsječku. Signali su ekstrahirani pomoću nestandardnih pristupa.

Funkcionalna magnetska rezonancija (fMRI) je specijalizirana vrsta snimanja pomoću magnetske rezonancije koja mjeri povećanje protoka krvi i oksigenaciju aktivnog dijela mozga

[35]. Ova metoda iskorištava činjenicu da se tijekom aktivnosti živčanih stanica povećava njihova potreba za kisikom i pojačava proizvodnja ugljičnog dioksida. Porast aktivnosti dane regije mjeri se odgovorom koji ovisi o razini oksigenacije u krvi, što definira ovisnost intenziteta signala magnetske rezonancije o razini oksigenacije krvi. Koncept fMRI temelji se na korištenju MRI skeniranja i proširuje ga promatranjem na temelju svojstava oksigenirane i deoksigenirane krvi.

Mozak koji se proučava smješten je u jako magnetsko polje paralelnih polja. Zavojnice skenera šalju određene frekvencije kratkotrajnih elektromagnetskih impulsa prema istraživanom objektu uzrokujući pobuđivanje protonskih spinova u atomskim jezgrama vodika, koji su sastavni dijelovi molekula vode, koja se nalaze u živim organizmima. Za konstantno magnetsko polje od 1,5 T, ova frekvencija je oko 63 MHz. Puls čini atome magnetiziranima i oni sami postaju izvor elektromagnetskog polja. Nakon prestanka djelovanja impulsa, elektromagnetsko zračenje uzrokovano povratkom spinova u neuzbuđeno stanje registrira se na zavojnicama koji djeluju kao prijemnici. Protoni koji se vraćaju u osnovno stanje emitiraju elektromagnetski val koji s vremenom slabi u frekvencije s koje je poslan elektromagnetski impuls. Brzina ovog slabljenja valova ovisi o karakteristikama magnetskih svojstava atoma pojedinih tkiva. Registracija tih valova pomoću takozvanih konstantnih gradijenata magnetskog polja omogućuje reprodukciju slike unutrašnjosti objekta koji se proučava pomoću računala.

2.4 Magnetoencefalografija (MEG) u odnosu na Elektroencefalografiju (EEG)

Prva očita razlika je u tome što EEG bilježi električnu aktivnost, a MEG magnetsku aktivnost mozga. Kod EEG-a se elektrode postavljaju na vlasište. MEG se izvodi pomoću dvostruke tikvice koja sadrži više zavojnica senzora, koja ne dodiruju glavu. MEG primarno otkriva magnetska polja inducirana unutarstaničnim strujama, dok je EEG vlasišta osjetljiv na električna polja generirana izvanstaničnim strujama. Iako je MEG osjetljiviji u otkrivanju struja koje su tangencijalne s površinom vlasišta, EEG je osjetljiv na tangencijalne i radijalne neuronske aktivnosti. MEG zahtijeva 3-4 cm^2 sinkronizirane kortikalne epileptičke aktivnosti da bi se otkrio epileptični skok, dok je za otkrivanje EEG skalpa vlasišta potrebno najmanje 6-20 cm^2 sinkroniziranog kortikalnog područja.


MEG pruža bolju prostornu razlučivost lokalizacije izvora (2-3 mm) od EEG-a (7-10 mm). Nedavna studija koja je uspoređivala omjere signal-šum (SNR) hipotetičkih izvora u različitim područjima mozga ukazala je na prednost MEG-a u odnosu na EEG u istraživanju

neokortikalnih epilepsija, iako su procijenjeni SNR-ovi bili usporedivi u sljepoočnom režnju. MEG podaci se mogu analizirati tehnikama modeliranja izvora, koje omogućuju lokalizaciju u tri dimenzije. Iako su tehnike modeliranja izvora dostupne za EEG vlasništva, modeliranje MEG izvora općenito je jednostavnije i preciznije iz tehničkih razloga. MEG je daleko skuplji od EEG-a.

EEG i MEG na tjemenu u osnovi odražavaju iste elementarne neuronske pojave. Na temelju temeljite usporedbe EEG-a i MEG-a [36] zaključeno je da su ove metode samo djelomično neovisne, tako da bilježenje obje može dati neke dodatne informacije o lokalizaciji izvora u mozgu.

EEG polje je skalarno i osjetljivo je na tangencijalne i na radijalne komponente dipolarnih izvora. Teoretski, radijalno orijentirani dipolarni izvor ne dovodi do magnetskog polja izvan sfernog volumenskog vodiča; posljedično tome, MEG nije osjetljiv na radijalne komponente dipolarnih izvora već na tangencijalne komponente [37]. Usporedna točnost lokalizacije izvora u mozgu s EEG i MEG testirana je pomoću ugrađenih izvora i utvrđeno je da je istog reda veličine [38].

Glavne prednosti MEG-a su njegova dobra prostorna rezolucija u odvajanju kortikalnih izvora zbog manjeg prostornog razmazivanja nego u EEG-u i njegova selektivnost prema aktivnosti kore, Hari [39]. Razlike i sličnosti između EEG i MEG prikazane su na *slici 2.7.*, gdje su prikazani grafikoni dipolne gustoće ekvivalentnih dipolarnih izvora EEG i MEG podataka u α oscilacijama.[40]



Slika 2.7. Prostorna raspodjela EEG / MEG α i μ dipolarnih izvora

Grafikoni dipolne gustoće EEG i MEG izvora α oscilacija naloženi su na MRI kriške. Vokseli u kojima su lokalizirane značajne količine ekvivalentnih dipolarnih izvora predstavljeni su u boji, od plave do onih koja sadrže najveću gustoću izvora ("žarišta"), do padajuće gustoće, crvene te zelene boje. Glavna vizualna α „žarišta“ EEG izvora lokalizirana su u bočnijim MRI rezovima od onih MEG-a, što vjerojatno proizlazi iz zakrivljenosti okcipitalne kortikalne površine, tako da dipolarni izvori smješteni na medijalnoj kortikalnoj površini uglavnom imaju tangencijalni oblik orijentacije, dok one smještene na konveksnosti okcipitalnog pola imaju uglavnom radijalne orijentacije. Ovaj kontrast odražava različitu osjetljivost MEG i EEG na tangencijalnu i radijalnu dipolarnu orijentaciju.

3. SUČELJA MOZGA I RAČUNALA POMOĆU STROJNOG UČENJA

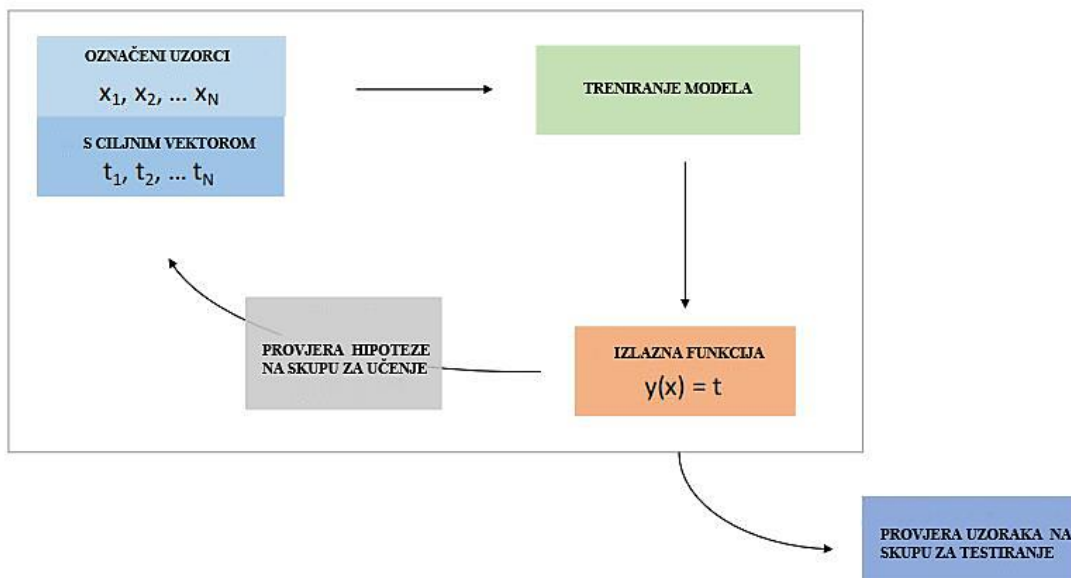
Najveći izazov za BCI je taj što nemaju svi isti mozak. Koristeći Strojno učenje, za svaku novu sesiju BCI mora učiti iz korisnikova mozga, ali ovo učenje treba vremena. Vrijeme koje BCI treba prilagoditi korisnikovom mozgu kako bi ispravno klasificirao korisnikove misli, poznato je kao vrijeme kalibracije.

3.1 Strojno učenje

Strojno učenje se koristi kada statičke upute, poput ručno izrađenih pravila i heuristike, nije moguće dizajnirati i programirati. Algoritam strojnog učenja koristi se za izradu predviđanja na temelju podataka i na temelju svojstava ulaznih primjera, poznatih kao podaci za treniranje (eng. training data ili eng. training set). Naveden je primjer kod korištenja algoritma za prepoznavanje lica. Gotovo je nemoguće stvoriti pravila za prepoznavanje lica, jer će doći do preopterećenja pravila i iznimki od pravila. Stoga, ako postoji osnovni model koji sadrži svojstva podataka, strojno učenje je preferirana tehnika koja će pokušati izgraditi model na temelju dostupnih training podataka, što je bliže osnovnom modelu.

Opći okvir za strojno učenje naveden je na sljedeći način, *slika 3.1.*[41]. Set za obuku sadrži n označenih uzoraka (x_1, x_2, \dots, x_n) , što ga čini nadgledanim problemom učenja, jer su oznake razreda za sve uzorke poznate i drže se u ciljnom vektoru (t_1, t_2, \dots, t_n) . Uzorci treninga x zajedno s ciljnim vektorom t koriste se za podešavanje parametara modela, konstruirajući izlaznu funkciju $y(x)$. Ako hipoteza za model dobro funkcionira, $y(x)$ bi trebao predvidjeti ispravne oznake klasa novih ulaznih uzoraka x , poznatih kao testni skup. Sposobnost modela da pravilno klasificira nove uzorke koji se razlikuju od skupa treninga poznato je pod nazivom generalizacija.

Drugi važan aspekt strojnog učenja je prethodna obrada podataka. Predobrada, također se naziva izdvajanjem značajki, a koristi se iz dva razloga: Prvi je razlog nadati se da ćemo moći riješiti lakši problem u novom niže-dimenzionalnom prostoru, na primjer, koristeći prosjeke intenziteta slike u podregijama slike, jer značajke dokazano dobro funkcioniraju u prepoznavanju lica. [42].



Slika 3.1. Opći okvir za algoritam strojnog učenja

Drugi je razlog ubrzanje računanja. Na primjer, ako se detekcija lica mora primijeniti na video podatke koristeći samo vrijednosti piksela kao ulaze, ulazni podaci koji se daju složenom algoritmu visoko su dimenzionalni, što rezultira dugim računskim vremenima. Ako se umjesto toga pronađu značajke koje se brzo izračunavaju bez gubljenja diskriminacijskih podataka, ovaj je postupak prikladniji za otkrivanje lica u stvarnom vremenu.

U slučaju nadzirane klasifikacije, imajući na umu važnost regularizacije i postupka ekstrakcije značajki, algoritam strojnog učenja trebao bi biti u stanju predvidjeti pouzdane ishode klase koje se mogu reproducirati. Budući da je algoritam strojnog učenja prethodno izgrađen, naučeni odnosi ili trendovi u podacima iz skupa obuke mogu imati sposobnost otkrivanja skrivenih uvida u podatke, te mogu pronaći zakonitosti koje se koriste za klasifikaciju novih podataka.

3.1.1 Prekomjerno prilagodavanje

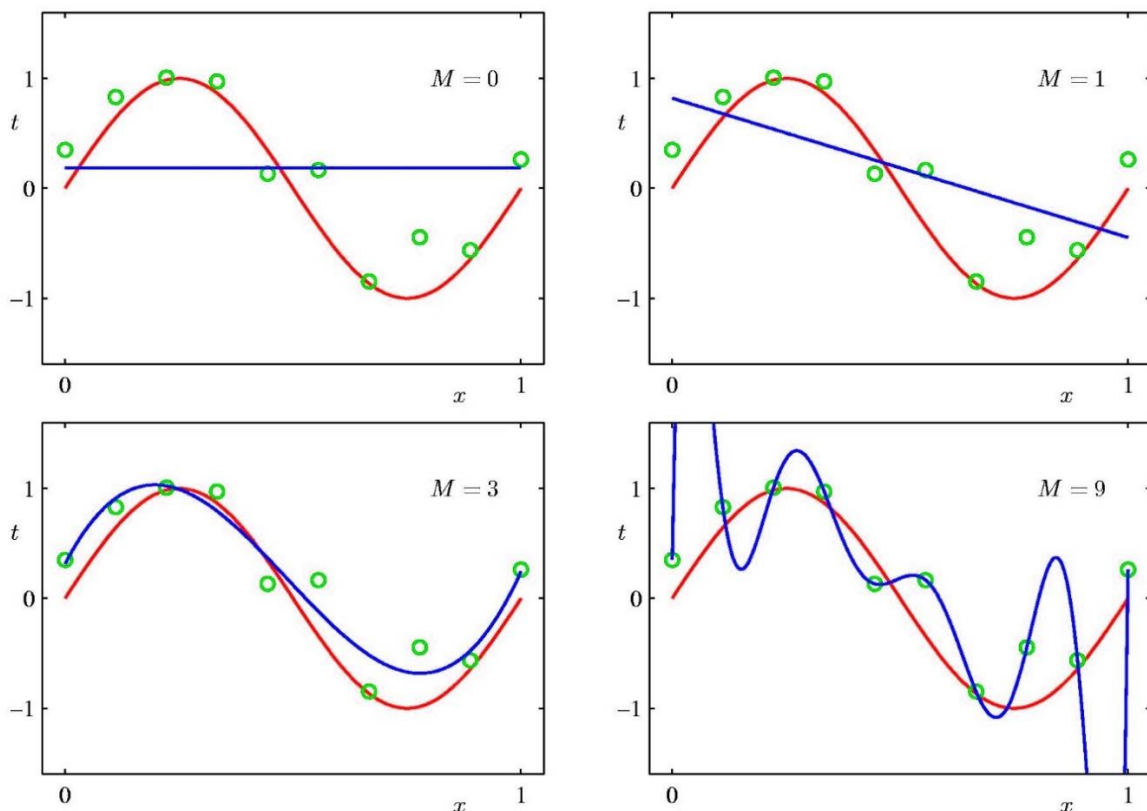
Prvi glavni izazov u strojnom učenju s kojim se treba suočiti je preklapanje. Jednostavno rečeno, ako je hipoteza našeg modela previše složena u usporedbi s količinom dostupnih podataka, doći će do preklapanja modela. Što se tiče točnosti klasifikacije, prekomjerno

prilagođavanje se događa kada se s povećanjem složenosti pogreška treninga smanjuje, ali se pogreška ispitivanja povećava.

U slučaju korištenja polinoma, na *slici 3.2.* prikazano je da je s porastom reda M polinoma krivulja bolje prilagođena podacima treninga, ali će loše raditi na novim podacima. To se može protumačiti na način da se krivulja prilagođava slučajnom šumu koji može biti prisutan u skupu testnih podataka.

Crvena linija prikazuje temeljnu polinomsku krivulju, plava linija je polinomska krivulja s redoslijedom M koju model koristi za predviđanje novih podataka. S porastom redoslijeda polinoma, training podaci se bolje provjeravaju, ali ako M postane veći od 3, model počinje prekomjerno odgovarati i testna pogreška će se povećati [43].

Izravni način rješavanja problema prekomjernog prilagođavanja jest upotreba više podataka, jer to omogućuje da model bude složeniji, ali s obzirom na to da su training podaci često oskudni, potrebna su i druga rješenja. Još dva dobra načina za rješavanje prekomjernog prilagođavanja je smanjenje broja značajki odabirom značajki i generaliziranjem, u primjeru ugradnje polinomske krivulje, ovo bi značilo smanjenje reda krivulje.




Slika 3.2. Primjer prekomjernog prilagođavanja

3.1.2 Strojno učenje za sučelja mozga i računala

Primjenom Strojnog učenja na temu BCI-a koristi se postavka kao na slici 3.3. Počevši od različitih pokusa zamišljenog kretanja lijeve i desne ruke, signali koje proizvede korisnik snimaju se pomoću EEG-a. Prije slanja EEG snimljenih podataka kod motoričkih detekcija računalu i obrade algoritmom, podaci se prethodno obrađuju pomoću filtera. Nakon prethodne obrade, značajke se daju u klasifikacijski model koji odlučuje za svako ispitivanje da li je bilo npr. kretanje lijevom ili desnom rukom.

Važan dio sučelja mozga i računala je točno predviđanje namjeravanog kretanja, koristeći izlučene vektore značajki. Ovo predviđanje snažno ovisi o vrsti klasifikatora, ali broj značajki i količina dostupnih podataka o trening podacima također igra značajnu ulogu.



Slika. 3.3. Sučelje mozak-računalo

Dvije klasifikacije koje se često koriste u klasifikaciji motoričkih slika su Linearna diskriminatorska analiza (LDA) i Metoda potpornih vektora (SVM) [44]. Osnova obje tehnike oslanja se na sposobnosti razlikovanja dvaju uvjeta na temelju vektora obilježja f_i . Kako su ovi vektori obilježja višedimenzionalni, problem bi postao jednostavniji ako se smanji dimenzionalnost ovih vektora obilježja. Cilj LDA je stvoriti hiperravan koja razdvaja obje klase s klasom vektora obilježja, ovisno o strani vektora u odnosu na hiperravan. SVM koristi isti princip za razlikovanje klasa, ali hiperravan se odabire na temelju maksimizacije margina. Bez obzira na to što SVM-ovi imaju dobru generalizaciju svojstva i neosjetljiviji su na pretreniranost i problem dimenzionalnosti, LDA je popularniji, jer je jednostavnija tehnika s nižim vremenom računanja. S druge strane, LDA nema dobru izvedbu kod složenih nelinearnih podataka, ali je prednost SVM-a je u brzini izvršavanja.

3.1.3 Linearna diskriminatorska analiza

Kao što je spomenuto, cilj ove tehnike je pronaći vektor projekcije w koji maksimalno odvaja vektore značajki f_i projiciranjem višedimenzionalnih vektora obilježja na jednu dimenziju, bez izazivanja gubitka informacija [43]. Najjednostavniji način razdvajanja dviju klasa je projiciranjem na jednu dimenziju na temelju maksimalnog odvajanja predviđenih sredstava klase. Ova metoda se koristi u statistici i strojnom učenju, te se korištenjem metode pronalazi

linearna kombinacija prediktora tako da se, posmatranjem u tom novom sustavu prediktora, klase kojima podaci mogu pripadati najviše razdvoje.

LDA se koristiti kao linearni klasifikator, na osnovu linearne kombinacije obilježja odlučujemo kojoj klasi pripada ili se odlučuje za smanjenje dimenzionalnosti. LDA računa linearne kombinacije prediktora koji najbolje opisuju podatke. Ideja diskriminantne analize je da se modelira raspodjela prediktora X u svakoj klasi za Y posebno, a da se onda koristi Bayes formula $P(Y|X)$.

Kada koristimo normalnu raspodelu u svakoj klasi, onda se radi o linearnoj ili kvadratnoj diskriminantnoj analizi. Zavisna varijabla je diskretna, ako uzima vrijednosti od 1 do k , a smatramo da uslovna raspodjela $X|Y = k$ ima gustoću $f_k(x)$.

Imamo i apriornu raspodjelu za Y , $\pi_k = P\{Y=k\}$. Bayesova formula je tada slijedećeg oblika :

$$P\{Y=k|X=x\} = \frac{\pi_k f_k(x)}{\sum_{l=1}^K \pi_l f_l(x)} \quad (3.1)$$


Ako pretpostavimo normalnu raspodelu u svakoj klasi, f_k normalne gustoće, onda dobijamo linearnu i kvadratnu diskriminantnu analizu.

Na jednoj i drugoj slici 3.4. na x osi nalaze se vrijednosti jedne nezavisne varijable. Na y osi su vrijednosti funkcije $\pi_k f_k(x)$ u slučaju kada imamo dvije kategorije pa i dvije funkcije. Uslovna vjerojatnost $P\{Y=k|X=x\}$ je proporcionalna $\pi_k f_k(x)$. Dakle na y -osi nisu prikazane funkcije $P\{Y=1|X=x\}$ i $P\{Y=2|X=x\}$, ali kod usporedbe ovih vjerojatnosti, za neko dato x_0 svodi se na usporedbi vrijednosti u x_0 .

Na istoj slici prikazana je i vertikalna linija $x=0$ koja ima posebno značenje, ako klasificiramo $x_0 < 0$, na tom intervalu lijevo od vertikalnog pravca crvena gustoća je veća od plave, pa se odlučujemo za prvu kategoriju. Ako je $x_0 > 0$, desno od obilježenog vertikalnog pravca, tu je plava gustoća veća od crvene, pa se odlučujemo za drugu kategoriju. Na slici desno smo uzeli drugu apriornu raspodelu $\pi_1=0.3$, $\pi_2=0.7$. Na y -osi desno, također su prikazane vrijednosti dvije funkcije $\pi_1 f_1(x)$ i $\pi_2 f_2(x)$. Da bismo klasificirali x_0 dovoljno je (zbog proporcionalnosti) uporediti u ovoj tački vrijednosti tih funkcija i odlučiti se za onu kategoriju kojoj odgovara veća vrijednost funkcije. Vertikalni pravac ima isto značenje samo što sada nije u nuli.

Iako logistička regresija obuhvaća sve slučajeve kao i diskriminantna analiza, diskriminantna analiza DA je bolja u nekim slučajevima. Kada su kategorije jasno razdvojene ,na primjeru kod malih vrijednosti prediktora odgovara sa 0, a velikim vrijednostima prediktora odgovara sa 1,

te su tada parametri logističke regresije nestabilni, uzimaju velike vrijednosti i imaju veliku disperziju.



Slika 3.4. Ilustracija metode diskriminantne analize

4. KLASIFIKACIJSKI ALGORITMI

Većina suvremenih sučelja mozga i računala BCI zasnovanih na elektroencefalografiji EEG temelje se na algoritmima strojnog učenja. Sintetizirane studije predstavljaju nove algoritme, u kojima se prvenstveno navodi kako su se koristili za uporabu u BCI sustavima, koji su bili ishodi i identificirali njihove dobre i loše strane. Dizajnirani algoritmi klasifikacije za BCI utemeljene na EEG-u mogu se podijeliti u četiri glavne kategorije: prilagodljivi klasifikatori, matrični i tenzorski klasifikatori, transferno učenje i duboko učenje, plus nekoliko drugih raznih klasifikatora. Među njima se pokazalo da su prilagodljivi klasifikatori uglavnom superiorniji od statičkih, čak i uz nenadgledanu prilagodbu. Transferno učenje se također pokazalo korisnim, iako su koristi od transfernog učenja i dalje nepredvidljive. Metode temeljene na Riemannovoj geometriji dosegle su najmoderniju tehnologiju izvedbe na više BCI problema i zaslužuju da ih se detaljnije istraži, zajedno s metodama temeljenim na tenzorima. Metode dubokog učenja još nisu pokazale uvjerljivo poboljšanje u odnosu na najsuvremenije BCI metode.

4.1 Prilagodljivi klasifikatori

Prilagodljivi klasifikatori su klasifikatori čiji parametri, pripisani svakoj značajki u linearnoj diskriminacijskoj hiperravni, se postupno ponovno procjenjuju i s vremenom se ažuriraju kao novi EEG podaci koji postaju dostupni [45-46]. To klasifikatoru omogućuje praćenje moguće promjene distribucije značajki a time i učinkovitost čak i sa nestacionarnim signalima poput EEG-a. Prilagodljivi klasifikatori za BCI prvi su put predloženi sredinom 2000-ih [47,48,49,46, 50], i pokazalo se da su obećavajući u izvanmrežnoj analizi. Od tada su predložene i testirane naprednije tehnike prilagodbe, uključujući mrežne eksperimente.

Prilagodljivi klasifikatori mogu upotrijebiti nadziranu i nenadgledanu prilagodbu, tj. sa ili bez poznavanja istinskih oznaka klasa dolaznih podataka.

Nadzornom prilagodbom poznaju se oznake pravih klasa dolaznih EEG signala i klasifikator se prekvalificira na dostupnim podacima o treningu nadopunjenim ovim novim, označenim dolaznim podacima ili se ažurira samo na temelju tih novih podataka [45,46]. Nadzirana BCI

prilagodba zahtijeva vođeno korisničko treniranje podataka za koje se nameću naredbe korisnika i tako su poznate odgovarajuće oznake EEG klase

Uz nenadgledanu prilagodbu, oznaka dolaznih EEG podataka je nepoznata. Kao takva, nenadzirana prilagodba temelji se na procjeni oznake razreda podataka za prekvalifikaciju, kako je raspravljano u [51], ili se temelji na prilagodbi nespecifičnoj za klasu, npr. općenito EEG podaci su svi istih klasa [52, 53] ili se kovarijancijska matrica [54] ažurira u model klasifikatora.

Istražena je i treća vrsta prilagodbe, između nadziranih i nenadgledanih metoda, polunadgledana prilagodba [55,56]. Polunadgledana prilagodba sastoji se od korištenja početnih označenih podataka i dolaznih neobilježenih podataka za prilagodbu klasifikatora. Za BCI, polunadgledana prilagodba obično se izvodi tako da u početku obučava nadzirani klasifikator na dostupnim označenim training podacima, zatim procjenjuje oznake dolaznih neobilježenih podataka s ovim klasifikatorom i na kraju se izvodi prilagođavanje klasifikatora pomoću ovih početno neobilježenih podataka dodijeljenih njihovim procijenjenim oznakama u kombinaciji s poznatim dostupnim označenim training podacima. Taj se postupak ponavlja kako postaju dostupne nove serije neobilježenih dolaznih EEG podataka.


4.2 Klasifikacija EEG matrica i tenzora

Uvođenje riemanovske geometrije u područje BCI osporilo je neke konvencije usvojene u klasičnim klasifikacijskim pristupima. Umjesto procjene prostornih filtara i ili odabranih značajki, ideja Riemanovog geometrijskog klasifikatora RGC (eng. riemann geometric classification) se ostvaruje mapiranjem podataka izravno u geometrijski prostor opremljen prikladnom metrikom. U takvom prostoru podacima se može lako manipulirati u nekoliko svrha, poput prosjeka, izravnavanja, interpolacije, ekstrapolacije i klasifikacije. Na primjer, u slučaju EEG podataka, mapiranje podrazumijeva izračunavanje nekog oblika kovarijantne matrice podataka. Načelo ovog mapiranja temelji se na pretpostavci da se snaga i prostorna raspodjela EEG izvora mogu smatrati fiksima za određeno mentalno stanje i takve informacije mogu se kodirati matricom kovarijance. Riemannova geometrija proučava glatke zakrivljene prostore koji mogu biti lokalno i linearno aproksimirani. Zakrivljeni prostor naziva se zakrivljeni i njegova linearna aproksimacija u svakoj točki je tangensni prostor.

U riemanovskom zakrivljenom prostoru tangensni prostor opremljen je unutarnjim produktom koji se glatko mijenja od točke do točke. To rezultira neeuclidskim pojmom udaljenosti između bilo koje dvije točke (npr. svaka točka može biti pokus) i posljedičnog pojma središta mase bilo kojeg broja točaka, *slika 4.1*. Najkraći put kod topološke mnogostrukosti koji se oslanja na dvije točke c_1 i c_2 nazvan je geodetskim, a njegova duljina je rimanova udaljenost između njih. Krivulje na topološkoj mnogostrukosti kroz točku preslikane su na tangensni prostor kao ravne crte (lokalna aproksimacija). Desno: G predstavlja središte mase (sredina) točaka c_1, c_2, c_3 i c_4 . Definirana G je točka koja umanjuje zbroj kvadrata udaljenost između sebe i četiri točke. Centar mase često se koristi kao predstavnik za datu klasu.

Stoga se umjesto korištenja euklidske udaljenosti, koja se naziva vanjska udaljenost, koristi unutarnja udaljenost koja je prilagođena geometriji rimanovog prostora, a time i načinu na koji su podaci mapirani [57, 58].

Među najčešćim matricnim mnogostrukostima koje se koriste za BCI aplikacije su mnogostruke hermitijanske ili simetrično pozitivno određene matrice SPD (eng. symmetric positive definite) [59] kada se radi o kovarijantnim matricama procijenjenim na EEG ispitivanjima, te Stiefelov i Grassmannov prostor [60] kada se radi o potprostoru ili ortogonalnoj matrici. Nekoliko problema strojnog učenja može se lako proširiti na topološku mnogostrukost koristeći prednosti njihovih geometrijskih ograničenja (tj. Učenja u topološkom prostoru). Nadalje, problemi optimizacije mogu se posebno formulirati na takvim prostorima, što dovodi do nekoliko novih metoda optimizacije i do rješenja novih problema [61]



Slika 4.1. Shematski prikaz Riemanovog prostora.

4.3 Prijenosno učenje

Jedna od glavnih hipoteza u strojnom učenju je da se training podaci, na kojima se klasifikator “uči” i da testni podaci, na kojima se klasifikator ocjenjuje, pripadaju istom prostoru značajki i slijede istu raspodjelu vjerojatnosti. U mnogim se primjenama, poput računalnog vida, biomedicinskog inženjerstva ili sučelja mozga i računala, ova hipoteza često narušava. Za BCI, promjena u raspodjeli podataka obično se događa kada se podaci prikupljaju od različitih subjekata i tijekom različitih vremenskih sesija.

Prijenosno učenje ima za cilj suočavanje s podacima koji krše ovu hipotezu iskorištavanjem znanja stečenog tijekom učenja zadanog zadatka za rješavanje drugog, ali povezanog zadatka. Drugim riječima, transferno učenje je skup razmatranih metodologija za poboljšanje izvedbe naučenog klasifikatora osposobljenog za jedan zadatak (također označen kao domena) na temelju informacija dobivenih tijekom učenja drugog zadatka.

Prirodno, učinkovitost transfernog učenja jako ovisi o tome koliko su ta dva zadatka dobro povezana. Na primjer, relevantnije je izvesti prijenosno učenje između dva pravopisna zadatka kognitivno evociranog potencijala P300 koja izvode dva različita subjekta, nego između jednog pravopisnog zadatka P300 i zadatka motoričke slike koju izvodi isti subjekt. Prijenosno učenje je važno, posebno u situacijama kada postoje obilni označeni podaci za jedan zadani zadatak, označeni kao izvorna domena, dok su podaci za drugi zadatak, označeni kao ciljna domena, rijetki. Doista, u takvim slučajevima, prijenos znanja iz izvorne domene u ciljanu domenu djeluje kao pristranost ili kao regularizator za rješavanje ciljanog zadatka.

Formalnije, domena je definirana prostorom obilježja X i marginalnom raspodjelom vjerojatnosti $P(X)$ gdje slučajna varijabla X poprima vrijednost X . Prostor obilježja povezan je s prostorom oznake Y i povezani su zajedničkom raspodjelom vjerojatnosti $P(X, Y)$ s $Y = y \in Y$. Zadatak je definiran prostorom oznake Y i prediktivnom funkcijom $f(\cdot)$ koja ovisi o nepoznatoj raspodjeli vjerojatnosti $P(X, Y)$.

Cilj je zadanog zadatka naučiti funkciju zasnovanu na $f(\cdot)$ i na parovima primjera $\{x_i, y_i\}_{i=1}^l$ gdje su $x_i \in X$ i $y_i \in Y$. Definicija za izvornu i ciljnu domenu $D_S = \{X_S, P_S(X)$ i $D_T = \{X_T, P_T(X)\}$ a izvorni i ciljni zadaci kao $T_S = \{Y_S, f_S(\cdot)\}$ i $T_T = \{Y_T, f_T(\cdot)\}$. Stoga, s obzirom na procjenu $f_T(\cdot)$ osposobljenu samo na temelju informacija iz ciljanog zadatka, cilj je učenja transfera poboljšati ovu procjenu iskorištavanjem znanja stečenog iz D_S i T_S uz $D_S \neq D_T$ ili $T_S \neq T_T$. Imajući na umu da se $D_S \neq D_T$ javlja kada je prostor obilježja X_S i X_T različit ili kada granične raspodjele

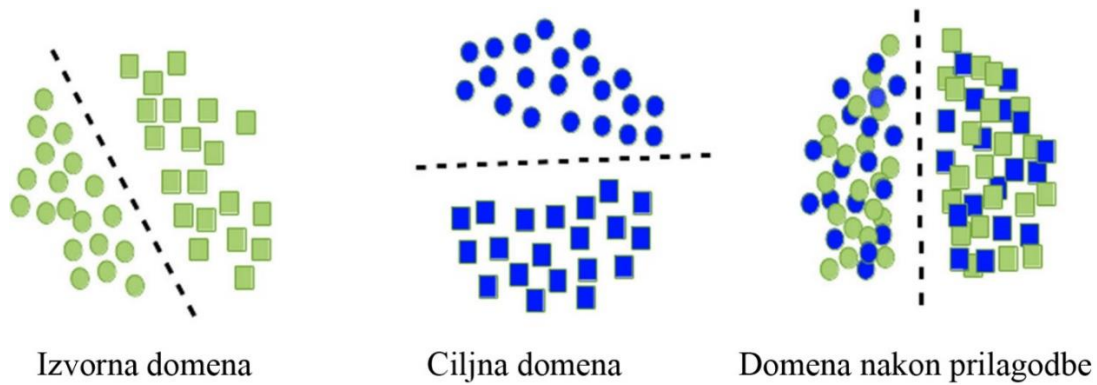
$P_S(X)$ i $P_T(X)$ nisu jednake. Slično tome, $T_S \neq T_T$ označavaju da su ili prostori sa oznakama različiti ili su funkcije predviđanja različite.

Na temelju postavki učenja, domena i zadataka, postoji nekoliko situacija primjenjivih na prijenos učenja. Na primjer, homogeno transferno učenje odnosi se na slučajeve kada je $X_S = X_T$, a prilagodba domene odnosi se na situacije u kojima se granične raspodjele vjerojatnosti ili uvjetne raspodjele vjerojatnosti ne podudaraju u izvornoj i ciljanoj domeni. Postavke u kojima su označeni podaci dostupni su u izvornoj i u ciljanoj domeni, a $T_S \neq T_T$, nazivaju se induktivnim učenjem prijenosa.

U BCI-u to može biti slučaj kada su izvorna domena i zadatak povezani s vizualnim potencijalima izazvanim P300, dok ciljana domena i zadatak uključuju slušne potencijale evocirane P300. Suprotno tome, transduktivno transferno učenje odnosi se na situacije u kojima su zadaci slični, ali su domene različite. Poseban je slučaj problem prilagodbe domene kada je neusklađenost domena uzrokovana neusklađenošću u marginalnoj ili uvjetnoj raspodjeli vjerojatnosti.

Postoji niz metoda i implementacija za rješavanje problema učenja prijenosa, koji ovise o specifičnim situacijama i primjeni domene. Za homogeno učenje transfera, koje je najčešća situacija u BCI-ima, u osnovi postoje tri glavne strategije. Ako se distribucije domena ne podudaraju, jedna od mogućih strategija je naučiti transformaciju podataka izvorne ili ciljane domene kako bi se ispravila neusklađenost distribucije [62,63]. Ako se vrsta neusklađenosti dogodi na marginalnoj raspodjeli, tada je moguća metoda kompenziranja promjene u raspodjeli [64]. Mnogi pristupi prijenosnog učenja također se temelje na pronalaženju zajedničkih prikaza značajki za dvije (ili više) domena. Budući da je prikaz ili dohvaćeni latentni prostor zajednički svim domenama, označeni uzorci iz izvorne i ciljane domene mogu se koristiti za obuku općeg klasifikatora [65, 66].


Klasična strategija je razmatranje pristupa čiji je cilj locirati reprezentacije u kojima se domene podudaraju. Sljedeći trend za prijenosno učenje je razmatranje metoda koje uče transformaciju podataka tako da se njihove distribucije podudaraju. Te transformacije mogu biti linearne, na primjer na temelju metoda jezgre [67, 68] ili nelinearne, korištenjem optimalne transportne strategije [69]. Na *slici 4.2.* je ilustracija cilja prilagodbe domene. Lijevo: domena izvora s označenim uzorcima. Sredina: ciljna domena (s oznakama i funkcijom odlučivanja). Klasifikator koji je treniran na izvornoj domeni će loše raditi. Desno: tehnika prilagodbe domene tražit će uobičajenu transformaciju reprezentacije ili mapiranje domena kako bi se podudarala s distribucijom izvora i ciljane domene.



Slika 4.2. Ciljna prilagodba domene

4.4 Duboko učenje

Dubinsko učenje je specifični algoritam strojnog učenja u sustavu u kojem su obilježja i klasifikator udruženo naučeni izravno iz podataka. Izraz duboko učenje je skovan za arhitekturu modela, koji se temelji na kaskadnom modulu za izvlačenju značajki koja se mogu trenirati. Zahvaljujući takvoj kaskadi, naučene značajke obično se odnose na povećanje razine koncepata. U ovom odjeljku opisati će se dva najpopularnija pristupa dubokog učenja za BCI: konvolucijske neuronske mreže i ograničeni boltzmannov stroj. Na slici 4.3. dat je primjer arhitekture dvaju najpopularnijih pristupa dubokog učenja. Lijevo na slici je arhitektura konvolucijske neuronske mreže. Zeleni blokovi se odnose na rezultate konvolutnog ulaznog signala s nekoliko različitih filtera. Desno na slici je naslagan ograničeni boltzmannov stroj. Skriveni slojevi su obučeni i puna mreža može biti fino podešena.



Slika 4.3. Arhitekture dvaju najpopularnijih pristupa dubokog učenja

Ograničeni boltzmann stroj RBM (eng. Restricted Boltzmann machine) je Markovljevo slučajno polje MRF (eng. Markov random field) [70] povezano s bipartitnim neutemeljenim grafikonom. Sastoji se od dva kompleta jedinica skrivenih i vidljivih jedinica:

$V = (V_1, \dots, V_m)$ m vidljive i n skrivene $H = (H_1, \dots, H_n)$. Vidljive jedinice koriste se za prikazivanje vidljivih podataka, a skrivene, hvataju neke ovisnosti između promatranih varijabli. Za uobičajenu vrstu RBM, jedinice se smatraju slučajnim varijablama koje uzimaju binarne vrijednosti (v, h) i W je matrica čiji su unosi $w_{i,j}$ utezi povezani s povezivanjem jedinice v_i i h_j . Zajednička vjerojatnost dane konfiguracije (v, h) se može modelirati u skladu s vjerojatnošću:

$$p(v, h) = \frac{1}{Z} e^{-E(v, h)} \quad (4.1)$$

s energetsom funkcijom:

$$E(v, h) = a^T v - b^T h - v^T W h. \quad (4.2)$$

gdje su a i b vektori težine pristranosti. Z je normalizirajući čimbenik u svrhu da je p(v, h) zbroj za sve moguće konfiguracije. Stoga je optimiziranjem svih parametara modela (W, b, a) moguće modelirati raspodjelu vjerojatnosti uočljivih varijabli. Ostala svojstva RBM-a kao i veze RBM-ova sa stohastičkim neuronskim mrežama detaljno su opisana u [71, 72]. Da bi se naučila raspodjela vjerojatnosti ulaznih podataka, RBM-ovi se obično obučavaju prema postupku koji se označava kao kontrastivno učenje o divergenciji [73]. Ovaj postupak učenja temelji se na gradijentnom usponu združene funkcije vjerodostojnosti (engl. likelihood function) kod training podataka. Derivat likelihood funkcije ulaza v može se lako izvesti [71], a srednja vrijednost ovog izvoda tijekom treninga na setu podataka dovodi do pravila:

$$\sum_v \frac{\partial L(W|v)}{\partial w_{i,j}} \propto \langle v_i h_j \rangle_{\text{podaci}} - \langle v_i h_j \rangle_{\text{model}} \quad (4.3.)$$

s tim da dvije zagrade označavaju očekivanje nad $p(h|v)$ $q(v)$ i nad modelom $(p(v,h))$, pri čemu je q empirijska raspodjela ulaza. Iako je prvi član ovog gradijenta izvediv, drugi ima eksponencijalnu složenost.

Kontrastivna divergencija ima za cilj aproksimaciju ovog gradijenta pomoću postupka Gibbsovog lanca koji izračunava binarno stanje h pomoću $p(h|v)$, a zatim dobiva procjenu v pomoću $p(v|h)$ [73]. Postoje i druge metode za aproksimaciju gradijenta likelihood funkcije RBM-a koje mogu dovesti do boljih rješenja, kao i metode učenja s kontinuiranim varijablama [74,75]. Gornji postupak omogućuje naučavanje generativnog modela ulaznih podataka pomoću jednostavnog sloja RBM-ova. Strategija dubokog učenja može se dobiti slaganjem nekoliko RBM-ova sa skrivenim jedinicama jednog sloja koji se koriste kao ulazi sljedećih slojeva. Svaki se sloj obično trenira na pohlepan način [72], a fino podešavanje može se izvršiti ovisno o konačnom cilju modela.

5. RAČUNALNO MODELIRANJE I PRIRODNA INTELIGENCIJA

Razumjeti kako je um proizašao iz materije jedno je od velikih preostalih pitanja u znanosti. Organizirane nakupine materije kao što je naš vlastiti mozak rađaju sva naša uvjerenja, želje i namjere, u konačnici omogućujući nam da razmišljamo o sebi kao i o svemiru iz kojeg potječemo. Ovo je pitanje desetljećima okupiralo kognitivne znanstvenike koji proučavaju računarske osnove uma. Ambiciji da se razumije prirodna inteligencija kakva se susreće u biološkim organizmima može se suprotstaviti motivacija za izgradnju inteligentnih strojeva, što je predmet umjetne inteligencije AI (eng. Artificial intelligence). Želja za oponašanjem ljudske inteligencije stvaranjem umjetno inteligentnih strojeva okupirala je čovječanstvo već stoljećima. Na primjer, mehanički ljudi i umjetna bića pojavljuju se u grčkoj mitologiji, a realni ljudski automati već su razvijeni u helenskom Egiptu [76].


Veliki napredak u raznim poljima istraživanja sada omogućuje napredak na problem razumijevanja prirodne inteligencije iz više kutova. S teoretskog gledišta solidno razumijemo računarske probleme koje rješava naš vlastiti mozak [77]. S empirijske točke gledišta, tehnološka otkrića omogućuju nam ispitivanje i manipulaciju moždane aktivnosti bez presedana, generirajući nove neuroznanstvene uvide u strukturu i funkciju mozga [78]. S inženjerske perspektive napokon smo u stanju izraditi strojeve koji uče rješavati složene zadatke, približavajući se i ponekad nadmašujući performanse na ljudskoj razini [79]. Ipak, ti naponi još uvijek nisu pružili potpuno razumijevanje prirodne inteligencije, niti su stvorili strojeve čija je sposobnost razmišljanja paralelna u općenitosti i fleksibilnosti kod kognitivne obrade u biološkim organizmima. Prirodna inteligencija se može bolje razumjeti spajanjem više komplementarnih znanstvenih disciplina [80]. Zagovarani pristup je obdariti umjetne agente sintetičkim mozgovima koji oponašaju misaone procese koji dovode do etološki relevantnog ponašanja u njihovim biološkim ekvivalentima. Motivaciju za ovaj pristup daje Braitenbergov zakon, koji kaže da je mnogo lakše razumjeti složeni sustav sastavljanjem od temelja, umjesto obrnutim inženjeringom iz podataka promatranja [81]. Ti sintetički mozgovima, koji se mogu koristiti u virtualnom ili stvarnom okruženju, mogu se zatim provjeriti prema neurobehavioralnim podacima i analizirati pomoću mnoštva teorijskih alata. Ovaj pristup ne samo da pojašnjava naše razumijevanje funkcije ljudskog mozga, već utire put za razvoj umjetnih agenata koja pokazuju doista inteligentno ponašanje [82]. Prije nego što krenemo u našu potragu za izgradnjom sintetičkog mozga kao modela prirodne inteligencije, moramo

formalizirati koje probleme rješavaju biološki mozgovi. Odnosno, prvo moramo shvatiti kako nastaje prilagodljivo ponašanje životinja i ljudi

5.1 Vjerojatnosti pristup pri modeliranju kognitivne arhitekture

Postoje različiti pristupi u razumijevanju prirodne inteligencije i razvijanje kognitivnih arhitektura koje je ovisno o razinama analize koje se razmatraju. Suvremena kognitivna znanost još uvijek prihvaća kognitivistički pristup uz vjerojatnosni pristup modeliranja spoznaje. Ovaj vjerojatnosni pristup polazi od ideje da su izazovi s kojima se suočava um često induktivne prirode, gdje promatrani podaci nisu dovoljni za jednoznačnu identifikaciju procesa koji ih je generirao [83]. To isključuje upotrebu pristupa koji se temelje na matematičkoj logici i zahtijeva kvantifikaciju stanja svijeta u smislu stupnjeva vjerovanja kao što je utvrđeno teorijom vjerojatnosti [84]. Vjerojatnosni pristup djeluje identificiranjem prostora hipoteza koji predstavlja rješenja induktivnog problema. Zatim se propisuje kako agent treba preispitati svoje uvjerenje u hipoteze s obzirom na podatke dane promatranim podacima.

Hipoteze se obično formuliraju u smislu vjerojatnosnih grafičkih modela koji obuhvaćaju strukturu neovisnosti između slučajnih varijabli od interesa [85]. Primjer takvog grafičkog modela prikazan je, *slika 5.1*. Primjer vjerojatnosnog grafičkog modela koji obuhvaća statističke odnose između slučajnih varijabli od interesa [86]. Ovdje su α i β hiper-parametri, θ_m je distribucija teme za dokument m , Φ_k je distribucija riječi za temu k , z_{nm} je tema za n -tu riječ u dokumentu m i w_{mn} je određena riječ. Velika slova K , M i N označavaju broj tema, dokumenata, odnosno riječi. Cilj je otkriti apstraktne teme iz promatranih riječi. Ovaj općeniti pristup zaključivanja naknadnih nad latentnim varijablama iz promatranih podataka zajednički je vjerojatnosnom pristupu.



Slika 5.1. Vjerojatnosni grafički model

5.2 Računalno modeliranje kognitivnih procesa

U ovome podpoglavlju istraženi su načini na koje se umjetne neuronske mreže mogu koristiti za razumijevanje i modeliranje aspekata prirodne inteligencije. Istraživanje započinje kako umjetne neuronske mreže mogu učiti iz podataka.

5.2.1 Učenje

Sposobnost mozga da se adaptivno ponaša ovisi o njegovoj sposobnosti da modificira vlastito ponašanje na temelju promjena okolnosti. Privlačnost neuronskih mreža proizlazi iz njihove sposobnosti oponašanja procesa učenja na učinkovit način ažuriranjem mrežnih parametara θ na temelju dostupnih podataka $D = \{z^{(1)}, \dots, z^{(N)}\}$, omogućujući izgradnju velikih modela koji su u stanju riješiti složene kognitivne zadatke. Učenje se nastavlja mijenjanjem parametara mreže θ tako da se njegov izlaz počinje sve više slagati s ciljevima dotičnog agenta. To se formalizira pretpostavkom postojanja funkcije troškova $J(\theta)$ koja mjeri stupanj u kojem agent odstupa od svojih ciljeva. J se izračunava izvođenjem neuronske mreže u načinu rada prema naprijed (od ulaza do izlaza) i uspoređujući predviđeni izlaz sa željenim izlazom. Tijekom svog života agent dobiva podatke iz svog okruženja (senzacije) uzorkovanjem iz distribucije koja generira podatke p_{data} . Cilj agenta je smanjiti očekivani rizik gdje je ℓ nastali gubitak po točki podataka z .

$$J^*(\theta) = E_{z \sim p_{\text{data}}}[\ell(z, \theta)] \quad (5.1.)$$

U praksi agent ima pristup samo konačnom broju točaka podataka koje agent doživi tijekom svog života, što daje skup treninga D . Ovaj set treninga može se predstaviti u obliku empirijske raspodjele $\hat{p}(z)$ koja je jednaka $1/N$ ako je z jednak jednom od N primjera. Stoga je u praksi cilj minimizirati empirijski rizik kao aproksimacija J^* .

$$J(\theta) = E_{z \sim \hat{p}} [\ell(z, \theta)] \quad (5.2.)$$

U stvarnosti se misli da mozak optimizira mnoštvo troškovnih funkcija koje se odnose na mnoge ciljeve koje želi postići u dogovoru [87]. Minimiziranje rizika može se postići korištenjem postupka gradijentnog spuštanja. Neka su θ parametri neuronske mreže (tj. sinaptičke težine). Učenje možemo definirati kao traženje optimalnih parametara θ^* na temelju dostupnih podataka o treningu D , takvih da je prikladan način približavanja θ^* lokalnim mjerenjem promjena nagiba $J(\theta)$ u ovisnosti o θ i poduzimanje koraka u smjeru najstrmijeg spuštanja.

$$\theta^* = \arg \min J(\theta) \quad (5.3.)$$

Ovaj postupak, poznat kao gradijentni spust, temelji se na zapažanju da ako je J definiran i diferenciran u susjedstvu točke θ , tada se J najbrže smanjuje ako se od θ ide u smjeru negativnog gradijenta $-\nabla_{\theta} J(\theta)$. Drugim riječima, ako koristimo pravilo ažuriranja s dovoljno malom stopom učenja ϵ tada je zajamčeno θ konvergirati na (lokalni) minimum od $J(\theta)$ ⁸.

$$\theta \leftarrow \theta - \epsilon \nabla_{\theta} J(\theta) \quad (5.4.)$$

Važno je da se gradijent može izračunati za proizvoljne umjetne neuronske mrežne arhitekture pokretanjem mreže u načinu unatrag (od izlaza do ulaza) i izračunavanjem gradijenta pomoću automatskog postupka diferencijacije [88].

Postoji mogućnost za tvrdnju da se algoritam povratnog širenja ne uspijeva povezati s učenjem iz biologije zbog nevjerojatnih pretpostavki kao što je činjenica da dodavanja naprijed i nazad koriste isti skup sinaptičkih utega. Stoga postoje brojni odgovori na moguću tvrdnju.

Prvo, moglo bi se zastupati mišljenje da je izračunavanje doprinosa greške svakog neurona nakon obrade serije podataka samo učinkovit način za dobivanje učinkovite mrežne arhitekture, bez zalaganja za biološku vjerojatnost učenja algoritam sam po sebi.

Drugo, ako je biološki vjerodostojno učenje cilj istraživanja, slobodno se može iskoristiti druge (hebbijevske) sheme učenja koje mogu bliže odražavati biološko učenje [89]. Napokon, istraživači su počeli iznositi argumente izračunavanje doprinosa greške svakog neurona nakon obrade serije podataka što možda ipak nije toliko biološki nevjerojatno [90].

5.2.2 Spoznavanje

Jedna od temeljnih vještina koju bi svaki inteligentni agent trebao posjedovati je sposobnost prepoznavanja obrazaca u svom okruženju. Svijet oko nas sastoji se od raznih predmeta koji mogu imati značaj. Mogućnost prepoznavanja jestive hrane, mjesta koja pružaju sklonište, sposobnošću prepoznavanja inteligentni agenti u tim slučajevima bi omogućavali naše preživljavanje.

Biološki mozak suočen je s problemom ako ne bi mogao prepoznati predmete iz sirovog osjetilnog unosa (vektori u R^n). Kako mozak može upotrijebiti incidentni osjetni unos kako bi naučio prepoznati one stvari koje su bitne za organizam? Formulacijom umjetnog neurona $y=f(w^T x)$.

Učeći odgovarajuće težine w , ovaj neuron može naučiti razlikovati različite kategorije predmeta. To je u osnovi ekvivalent klasičnom modelu poznat kao perceptron [91], koji je korišten za rješavanje jednostavnih problema s prepoznavanjem uzoraka putem jednostavnog mehanizma za ispravljanje pogrešaka. Također odgovara osnovnom linearnom-nelinearnom LN (eng. linear nonlinear) modelu koji se opsežno koristi za modeliranje i procjenu receptivnog polja neurona ili populacije neurona [92].

Jednoslojne umjetne neuronske mreže poput perceptrona sposobne su riješiti zanimljive probleme učenja. Istodobno, ograničenog su opsega jer mogu riješiti samo linearno odvojene probleme klasifikacije [93]. Da bismo prevladali ograničenja perceptrona, možemo proširiti njegove mogućnosti ublažavanjem ograničenja da su ulazi izravno povezani s izlazima.

Višeslojni perceptron MLP (eng.multilayer perceptron) je povratna mreža koja generalizira standardni perceptron imajući skriveni sloj koji se nalazi između ulaznog i izlaznog sloja.

MLP možemo napisati s više izlaznih jedinica kao $y = g(Wf(Vx))$, gdje V označava težinu skrivenog sloja, a W težinu izlaznog sloja. Uvođenjem skrivenog sloja, MLP-ovi stječu sposobnost učenja internih prikaza [94]. Važno je da MLP može približiti bilo koju kontinuiranu funkciju proizvoljnom stupnju točnosti, s obzirom na dovoljno velik, ali konačan broj skrivenih neurona [95].

Složeni sustavi imaju tendenciju hijerarhijske i modularne prirode [96]. Sam živčani sustav možemo smatrati hijerarhijski organiziranim sustavom. To je ilustrirano hijerarhijskim dijagramom vizualnog korteksa Felleman&van Essen [97], predložena hijerarhijska organizacija prefrontalne kore [98], pogled na motorički sustav kao kolonu za upravljanje ponašanjem [99], i tvrdnja da anteriorni i stražnji korteks odražavaju hijerarhijski organizirani izvršni i perceptivni sustav [100].

Hijerarhiju modeliramo dubokom neuronskom mrežom DNN (eng.deep neural network) sastavljenoj od više skrivenih slojeva [101]. DNN odgovara nizu LN modela, generalizirajući koncept osnovnih receptivnih modela polja. Pokazalo se da donose izvedbu na ljudskoj razini u zadacima kategorizacije objekata [102]. Najnovija DNN rješenja čak su sposobna predvidjeti kognitivna stanja drugih agenata.

5.2.3 Pamćenje

Sposobnost opažanja okoline također podrazumijeva da agenti mogu pohraniti i dohvatiti prošla znanja o predmetima i događajima u njihovoj okolini. U povratnim mrežama razmatranim u prethodnom odjeljku, ovo je znanje kodirano u sinaptičkim utezima kao rezultat učenja. Sjećanja na prošlost također se mogu pohraniti u obrascima neuronske aktivnosti od trenutka do trenutka. To zahtijeva dostupnost bočnih ili povratnih veza kako bi se omogućila ponovljena obrada [103], [104]. Ponavljajuću obradu može provesti rekurentna neuronska mreža RNN (eng. recurrent neural network) [105], [106], definirana :

$$y_n = f(Wy_{n-1} + Ux_n) \quad (5.5)$$

tako da aktivnost neurona u trenutku n ovisi o aktivnosti u vrijeme $(n-1)$ kao i trenutni ulaz odozdo prema gore.

RNN-ovi se mogu tumačiti kao numeričke aproksimacije diferencijalnih jednadžbi koje opisuju neuronske modele temeljene na brzini [107], i pokazalo se da su univerzalni aproksimatori dinamičkih sustava [108]. Njihovi se parametri mogu procijeniti pomoću varijante povratnog razmnožavanja, koja se naziva povratnim širenjem kroz vrijeme [109].

Kad se razmatra percepcija, arhitekture s prosljeđivanjem procesa čine se dovoljnim. Na primjer, latentne pojave neurona u inferiorno-temporalnoj kori majmuna tijekom vizualne obrade iznose oko 100 ms, što znači da postoji vrijeme uzorkovanja za prijenos samo nekoliko šiljaka [110]. To sugerira da je prepoznavanje objekata u velikoj mjeri automatski proces prosljeđivanja [111]. Međutim, ponovljena obrada važna je i u percepciji jer pruža sposobnost održavanja stanja. To je važno za otkrivanje istaknutih obilježja u prostoru i vremenu [112].

Štoviše, na percepciju snažno utječu procesi odozgo prema dolje, posredovani povratnim vezama [113]. RNN-ovi su također korišteni za modeliranje radne memorije, kao i funkcije hipokampusa, koja je uključena u razne procese povezane s memorijom [89], [114], [115].

Posebna vrsta RNN-a je mreža Hopfield [116] gdje je W simetričan i $U = 0$. Učenje u Hopfield mreži temelji se na hebbijskoj shemi učenja. Hopfield mreže su privlačne mreže koje se konvergiraju u stanje koje je lokalni minimum energetske funkcije. Opsežno su korišteni kao modeli asocijativnog pamćenja [117]. Čak se pretpostavljalo da se sanjanje može promatrati kao proces nenaučavanja koji se rješava lažnih minimuma u mrežama atraktora, čime se poboljšava njihov skladišni kapacitet [118]

5.2.4 Izvođenje

Sposobnost generiranja odgovarajućih radnji je ono što u konačnici pokreće ponašanje. U stvarnim okruženjima takve se radnje obično moraju zaključiti iz signala r_t koje pruža okoliš. Ovo je predmet podržnog učenja RL (eng. Reinforcement learning) [119]. Algoritmi podržanog učenja bili su presudni u treningu neuronske mreže koje imaju sposobnost djelovanja. Takve mreže uče generirati prikladne akcije isključivo promatrajući varijable koje su proizvedene prethodno generiranim radnjama. RL algoritmi dolaze u inačicama bez modela i na verzijama temeljenih na modelu.

U postavci bez modela, optimalne se radnje uče isključivo na temelju varijable koja je stečena izvršavanjem akcija u prošlosti. Nasuprot tome, u postavkama temeljenim na modelu, eksplicitni model okoliša koristi se za predviđanje posljedica radnji koje se izvršavaju. Važno je da se RL algoritmi temelje na jasnim podudarnostima s uobičajenim i ciljno usmjerenim učenjem u neuroznanosti [120], [121]. Različiti pristupi podržanog učenja bez modela korišten je za razvoj različitih neuronskih mreža. Na primjer, Q-učenje se koristilo za osposobljavanje mreža koje igraju Atari igre [122], te metode gradijenta korištene su za igranje igara na ploči [123] i rješavati probleme u (simuliranoj) robotici [124], [125], učinkovito zatvarajući ciklus percepcije-akcije.

Pokazalo se da evolucijske strategije postaju koristan pristup za rješavanje izazovnih kontrolnih problema [126]. Stvaranje radnje mora ovisiti o sposobnosti integriranja dokaza tijekom vremena, jer u suprotnom zajamčeno ćemo djelovati suboptimalno. Odnosno, za stanja koja se kvalitativno razlikuju mogu se donijeti ista donosiocu odluke, što dovodi do neoptimalnih politika. Razmotrimo na primjer osjećaj nadolazećeg predmeta. Optimalna odluka presudno ovisi o tome približava li se ovaj objekt ili se povlači, što se može utvrditi uzimajući u obzir prošle senzacije. Ova je pojava poznata kao perceptivno mapiranje [127].

Ključna sposobnost bioloških organizama koja zahtijeva ponovljenu obradu je njihova sposobnost snalaženja u svom okruženju, posredovana hipokampalnom formacijom [128]. Nedavni radovi pokazuju da su posebne karakteristike stanica hipokampusa, kao što su stabilne krivulje ugađanja koje se prenamjenjuju u okruženju, obnavljaju sa treniranjem neuronskih mreža na navigacijskim zadacima [129].

Sposobnost integriranja dokaza također omogućava agentima da selektivno uzimaju uzorke iz okoline, kao što je maksimalizacija količine prikupljenih informacija. Općenito, pokazalo se da RNN-ovi koji su trenirani pomoću RL-a na raznim kognitivnim zadacima daju svojstva koja su u skladu s pojavama uočenim u biološkim neuronskim mrežama [130], [89].

5.2.5 Procjenjivanje

Moderne teorije o radu ljudskog mozga pozivaju se na ideju da se mozak može promatrati kao stroj za predviđanje koji se nalazi u stanju kontinuiranog generiranja predviđanja [131], [132], [133], [134]. Ovaj pogled na mozak kao na stroj za predviđanje koji vrši nesvjesno zaključivanje ima dugu povijest, vraćajući se na osnovno djelo Alhazena i Helmholtza [135].

Suvremena gledišta dodjeljuju ovaj proces u termine Bayesova zaključivanja, gdje mozak ažurira svoj unutarnji model okoline kako bi objasnio podatke koji utječu na njegova osjetila, terminima koji se nazivaju Bayesovom hipotezom o mozgu [84], [136]. Isto obrazloženje temelji se na principu slobodne energije, uz pretpostavku da biološki sustavi minimaliziraju funkciju slobodne energije svojih unutarnjih stanja [137].

Predviđanja se mogu smatrati ključnim za generiranje adaptivnog ponašanja, jer će predviđanje u budućnosti agentu omogućiti odabir prikladnih radnji u sadašnjosti [138], [139]. Predviđanje je najvažnije u pristupima temeljenim na modelu, jer zahtijeva od agenata da planiraju svoje akcije predviđanjem ishoda budućih radnji [120]. To je snažno povezano s pojmom predigre budućih događaja koji održavaju planiranje puta [140]. Takva predigra uočena je u sekvencama stanica hipokampalnog područja, što daje daljnju potporu ideji da je hipokampalna formacija uključena u ciljanu navigaciju [140], [141]. Predviđanje također omogućava agentu da prospektivno djeluje na očekivana odstupanja od optimalnih uvjeta. Također je fokus na ispravljanju pogrešaka i stabilnosti koje isto prevladavaju u radu kibernetskog pokreta [142].

Dalje, prediktivna obrada se povezuje s konceptom alostaze, gdje agent aktivno pokušava predvidjeti buduća stanja kao što je minimaliziranje odstupanja od optimalnih homeostatskih uvjeta. Također je od ključne važnosti za teoriju optimalne povratne sprege, koja pretpostavlja da motorni sustav ispravlja samo ona odstupanja koja ometaju ciljeve zadatka [143].

Pojam prediktivne obrade bio je vrlo utjecajan u istraživanju neuronskih mreža. Na primjer, prediktivna obrada pruža osnovu za prediktivne modele kodiranja koji uvode specifične arhitekture neuronske mreže u kojima se povratne veze koriste za prijenos pogrešaka predviđanja [144], [145]. Također je dovelo do razvoja širokog spektra generativnih modela koji su u stanju predvidjeti svoja osjetilna stanja, koja se nazivaju i fantazijama [146]. Takve fantazije mogu igrati ulogu u razumijevanju kognitivne obrade koja uključuje slike, radno pamćenje i sanjanje.

Generativni modeli također nude način izvođenja učenja bez nadzora, jer ako je neuronska mreža sposobna generirati predviđanja tada nesklad između predviđenih i opaženih podražaja može služiti kao instrukcioni signal. Kanonski primjer je Boltzmannov stroj, koji je stohastička varijanta Hopfieldove mreže, koja je u stanju otkriti pravilnosti u trening podacima pomoću jednostavnog algoritma učenja bez nadzora [147], [148].

Slijedeći klasični primjer je Helmholtzov stroj koji uključuje obradu odozdo prema gore i odozgo prema dolje [149].

Drugi, noviji primjeri generativnih modela temeljenih na umjetnim neuronskim mrežama (eng. artificial neural network) ANN su mreže dubokih vjerovanja [150] i generativne kontradiktorne

mreže [151]. U nedavnom radu navedeno korištenje ovih modele za predviđanje budućih osjetljivih stanja iz trenutnih opažanja [152], [153], [154]

5.2.6 Rasuđivanje

Iako su ANN-ovi sada sposobni rješavati složene zadatke poput djelovanja u prirodnom okruženju ili igranja teških društvenih igara, još uvijek bi se moglo tvrditi da oni "samo" izvode sofisticirano prepoznavanje uzoraka, umjesto da pokazuju simboličke sposobnosti zaključivanja koje karakteriziraju naš vlastiti mozak. Pitanje jesu li konekcionistički sustavi sposobni za simboličko zaključivanje ima dugu povijest i o njemu su raspravljali razni istraživači [155]. Jedan od primjera je razvoj „različitih računala“ koji uče implementirati algoritme na temelju konačne količine training podataka [156].

Rezultirajuće neuronske mreže izvršavaju varijabilno vezanje i sposobne su se nositi sa strukturama promjenjive duljine, što prije nije bio slučaj i razlog protiv korištenja ANN-ova za objašnjavanje kognitivne obrade [156], [157].

Sljedeći je primjer razvoj neuronskih mreža koji mogu odgovoriti na proizvoljna pitanja o tekstu, slikama i filmovima, što zahtijeva duboko semantičko znanje o iskustvenom podražaju [158], [159], [160]. Pokazalo se da su i noviji modeli sposobni za kompozicijsko rasuđivanje što je važan sastojak za objašnjenje sustavnosti ljudske misli [157], [161], [162]. Te se arhitekture često koriste distribucijskom semantikom, gdje su riječi kodirane kao stvarni vektori koji bilježe značenje riječi [163], [164].

Nekoliko drugih svojstava karakterizira procese ljudskih misli, kao što su intuitivna fizika, intuitivna psihologija, relacijsko rasuđivanje i uzročno rasuđivanje [165], [166].

Sljedeće presudno obilježje inteligentnih sustava je da oni mogu objasniti što rade [167]. To zahtijeva da agenti duboko razumiju svoj svijet. Ta bi svojstva trebala biti ponovljena u neuronskim mrežama ako žele poslužiti kao točni modeli prirodne inteligencije. Nove arhitekture neuronske mreže polako počinju poduzimati korake u ovom smjeru [168], [169], [170].

6. KLASIFIKACIJA SLIKOVNIH VREMENSKIH SERIJA EEG SIGNALA PRI RJEŠAVANJU MENTALNIH ZADATAKA

Tehnologija je na mnogo načina utjecala na naš način poučavanja i učenja. Učenicima se, bez obzira na dob, predstavljaju različiti sustavi učenja, od tradicionalnih tečajeva u učionicama do internetskih razreda i detaljnih video lekcija. Kakvo god okruženje za učenje odabrali, uzimajući prave povratne informacije su bitan dio procesa učenja. Ovaj rad predstavlja značajan uvid sustava učenja koji koristi sučelje mozak-računalo za poboljšanje povratnih informacija između učenika i sustava.


6.1 Uvod

Uspjeh na tržištu sve više ovisi o učenju, točnije cjeloživotnom učenju. Ideja kontinuiranog obrazovanja nije nova jer je opisana kao dio svačijeg života davne 1929. godine [171]. Da bi pripravili učenike za kreativne i cjeloživotne učenike u tijelu znanja koji brzo raste, tehnologija u obrazovanju, uglavnom personalizirana okruženja za učenje igraju važnu ulogu u poboljšanju izvedbe [172], [173]. Razvojem i raširenošću internetske tehnologije svjedoci smo raznih novih metoda isporuke sadržaja. Štoviše, promjenjivi trendovi u obrazovnoj tehnologiji povećali su pristup tečajevima (npr. MOOC-ovi), promijenili način poučavanja primjenom tehnologije u nastavi (poput podučavanja u "preokrenutoj učionici" i adaptivnog učenja) [174]. Ali proces kontinuiranog učenja nije ograničen samo na studente, djecu i mlade koji pohađaju škole, to je i dio svakodnevnog života odraslih. Međutim, većina ljudi jednostavno ne zna kako učiti. To je posebno problematično na masivnim otvorenim internetskim tečajevima gdje su primijećene neimpressivne stope završetka studija s masovnim rastom stope napuštanja škole [175]. Svako okruženje za učenje trebalo bi podržati učenike u prijelazu od njihovih intuitivnih, često pogrešnih ili nepotpunih ideja do dubokog razumijevanja pojma. Takvo okruženje potiče učenika da zna ono što ne zna, čineći neuspjehe produktivnim [176]. U stvarnom internetskom ekosustavu učenja, učenje učenja može se definirati kao navigacijska vještina prepoznavanja blokirajućih raspoloženja i prebacivanja učenika na raspoloženja koja poboljšavaju učenje [177].

Prepoznavanje zašto neki učenici uče i postižu cilj, a drugi ne, postavlja ključno pitanje od početka sustavnog obrazovanja. Isto se može odnositi na svako okruženje za učenje, ne samo na ono formalno. Jedna vrsta osjećaja kod učenika, ispitna anksioznost učenika, dobila je široku znanstvenu pozornost [178], [179], [180], [181], [182]. Istodobno, važnost ocjenjivanja u procesu učenja, posebno one koja se koristi za pristup učenju, široka je priznata. Rezultat meta analize o učincima povratnih informacija u računalnom okruženju dosljedno je pokazivao da su složenije povratne informacije dovele do većih ishoda učenja [183]. Kada se gleda prezentacija materijala učitelja i adaptivnog okruženja za učenje, materijali koji se prezentiraju učeniku obično se prezentiraju u uglađenom obliku koji sprečava učenika da čini pogreške zbog kojih se osjećaju zbunjeno. Isto se odnosi na proces u kojem se učenik oporavlja od pogrešaka kada bi učenik trebao prevladati frustraciju. Učitelji koji rade u području STEM-a (znanost, tehnologija, inženjerstvo i matematika) razumiju da proces učenja uključuje neuspjeh i povezane afektivne reakcije. Kada učenici shvate da nisu uspjeli (obično na ispitima ili kvizovima), oni vjeruju da ne shvaćaju činjenice kako treba, onda vjeruju da ili 'nisu dobri u ovome', 'ne mogu to učiniti', ili da su jednostavno 'glupi' kad su ovi predmeti u pitanju [184]. Dobri učitelji vrlo su vješti u prepoznavanju i rješavanju emocionalnog stanja učenika koji im pomažu u procesu učenja. Iako vješti ljudi mogu s različitim stupnjevima točnosti procijeniti emocionalno stanje, istraživači napreduju dajući računalima slične sposobnosti [185], [186], [187], [188]. Kao što je prethodno rečeno, neki učitelji vrlo vješto prepoznaju emocionalno stanje učenika, pa bi bilo praktično da se mogu spojiti internetsko obrazovanje i obrazovanje licem u lice. Mješoviti modeli učenja stavljaju učenika u središte procesa učenja, koristeći tehnologiju da stvori više angažirano i učinkovitije okruženje za učenje. Kombinirano učenje kombiniranje je nastavne prakse najbolje od ljudskih i računalnih metoda poučavanja [189], [190], [191]. U kombiniranim modelima učenja, učitelji mogu prepoznati praznine u učenju uz pomoć računala. Da bi otkrilo emocionalno stanje učenika, računalu je potrebno nekakvo sučelje. Dobar kandidat je tehnologija Mozak - računalno BCI koji se kao moćan alat koristi za komunikaciju između sustava učenja i korisnika [192], [193], [194], [195].

6.2 Opis sustava

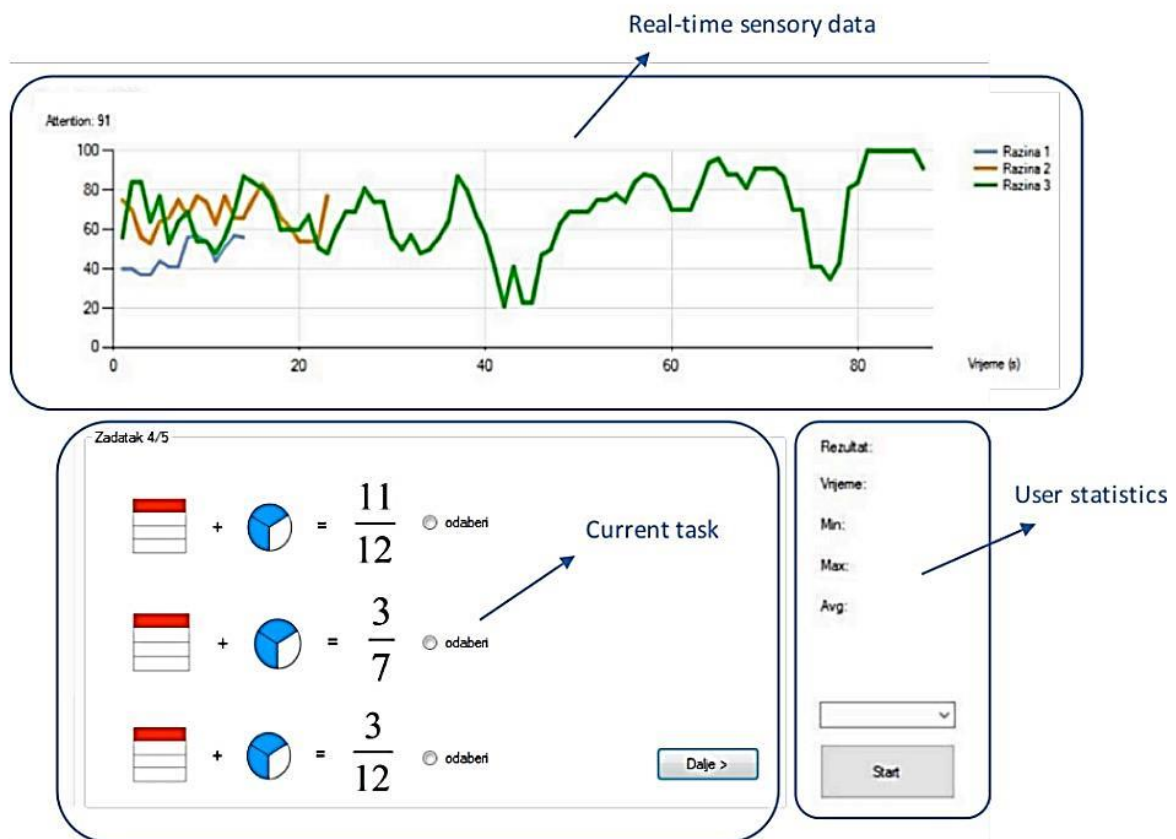
Fizički (hardverski) dio sustava koristi EEG bio senzor Neurosky Mindwave. Ovaj se senzor sastoji od dva dijela - slušalice za otkrivanje moždanih valova i USB prijamnika koji se koristi za prijenos podataka između slušalice i računala. Prilikom prikupljanja podataka (tj. otkrivanja moždanih valova) slušalice se postavlja na glavu korisnika, s jednom elektrodom koja dodiruje čelo korisnika, a drugom povezanom s ušnom školjkom korisnika. *Slika 6.1* prikazuje dijagram korištene slušalice i njenih glavnih dijelova.



Slika 6.1. EEG slušalice Neurosky Mindwave

Softverski dio sustava sastoji se od jedne računalne aplikacije koja je razvijena pomoću programskog jezika C#. Trenutno aplikacija ima samo jedan aktivni modul - za skeniranje moždanih valova. Korisničko sučelje u ovom modulu podijeljeno je u tri dijela. Na početku, korisnici moraju povezati aplikaciju sa slušalicama (jednostavnim pritiskom na gumb, pod pretpostavkom da su slušalice uključene i pravilno postavljene). Nakon uspostavljanja uspješne veze, korisnici mogu birati između različitih vrsta vježbi s različitim poteškoćama. Nakon

odabira odgovarajuće vježbe, korisnicima se u donjem lijevom kutu zaslona prikazuju odabrani matematički ili logički zadaci, pri čemu svaki zadatak prikazuje jedan točan i dva netočna odgovora. Tijekom cijelog postupka korisnici mogu vidjeti svoje statistike (broj točnih odgovora, proteklo vrijeme itd.) u donjem desnom kutu. Gornji dio korisničkog sučelja rezerviran je za prikaz dijela zabilježenih podataka u stvarnom vremenu. U postavkama aplikacije korisnici mogu odabrati koje podatke bi željeli da se prikazuju. Prema zadanim postavkama, korisnicima se prikazuje njihova koncentracija. Osim što korisnicima daje povratne informacije, ovo se također može koristiti za lako otkrivanje ispravnosti slušalica. Primjer korisničkog sučelja tijekom faze snimanja prikazan je na slici 6.2.



Slika 6.2. Korisničko sučelje s označenim odjeljcima

Uz podatke prikazane na korisničkom sučelju, aplikacija također u pozadini prikuplja razne podatke koji se kasnije koriste za procjenu i obradu. Aplikacija prikuplja sve vrste moždanih valova (alfa, beta, gama, delta i theta), razinu meditacije (na skali od 0 - 100), razina koncentracije (također od 0-100) i neobrađene podatke senzora.

Razine meditacije i koncentracije izračunavaju se na temelju neobrađenih podataka u slušalicama pomoću vlasničkog algoritma Mindwave koji nije javno dostupan, ali u kombinaciji s ostatkom podataka ti su signali također korisni. Svi signali imaju frekvenciju uzorkovanja oko 1 Hz, osim neobrađenih podataka signala koji imaju brzinu uzorkovanja od 512 Hz. Ti se signali prikupljaju u slušalicama i prenose na računalo putem bežičnog signala. Uz to, aplikacija uparuje svaku instancu primljenih informacija s povezanim metapodacima prikupljenim iz ponašanja korisnika. Svaka radnja koju korisnik izvrši unutar aplikacije bilježi se i sinkronizira s primljenim senzornim podacima prema njihovim vremenskim oznakama. Korištenje ovog pristupa negira moguće razlike između prikupljenih podataka uzrokovane kašnjenjem u komunikacijskom kanalu.

6.3 Eksperimentalna faza

Glavni cilj eksperimenta bio je prikupiti eeg podatke od učenika u stvarnim scenarijima, prilikom rješavanja mentalnih zadataka, obraditi eeg podatke. Da bismo testirali izvedivost ovog pristupa, u početku smo se koncentrirali na sljedeća istraživačka pitanja:

Q1. Možemo li koristiti jednostavni, pristupačni i praktični EEG uređaj u stvarnoj učionici za implementaciju sustav koji koristi BCI?

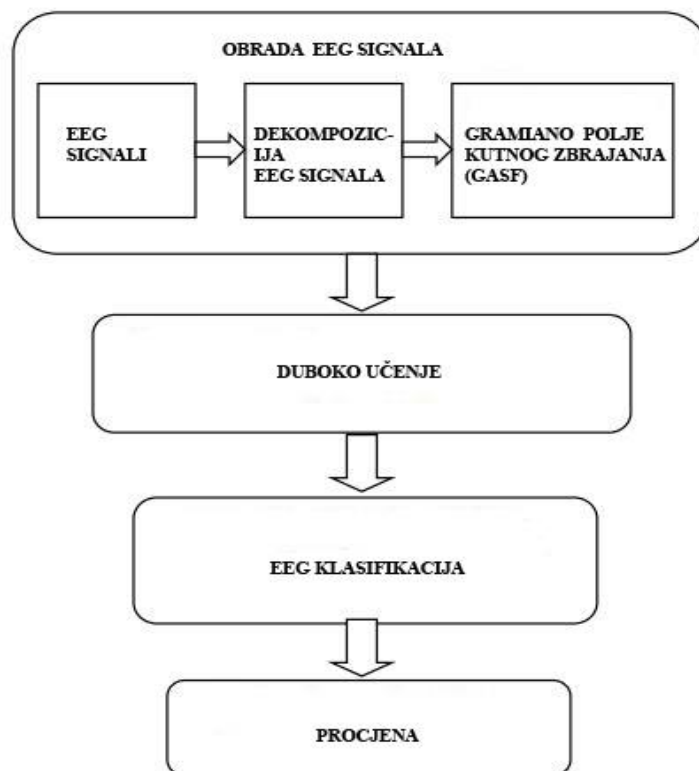
Q2. Jesu li dobiveni podaci dovoljni za prepoznavanje mentalnih stanja i odgovarajuće razine znanja?

Q3. Postoji li vidljiva veza između vrijednosti moždanih valova i različitih radnji korisnika?

6.4 Metodologija

Za prikupljanje podataka tijekom ovog eksperimenta koristili smo odgovarajuću kvalitativnu metodu istraživanja s opisnim pristupom, uglavnom kroz promatranje sudionika i intervju [196,], [197]. Promatranje sudionika bilo je javno i uz umjereno sudjelovanje istraživača gdje su intervjui bili nestrukturirani jer je to bilo najprikladnije za našu ciljnu skupinu. Ciljna skupina za eksperiment je odabrana iz više 6. i 7. razreda osnovnoškolske djece. Jedan od preduvjeta za postizanje široke primjene i prihvaćanja ove vrste sustava je biti što neupadljiviji. Idealno bi bilo da studenti ne budu svjesni postupka snimanja. Naravno, koristeći trenutno dostupnu tehnologiju, to je još uvijek nemoguće, a važno je testirati koliko upotreba trenutnog EEG hardvera utječe na studente. Kao što je prethodno opisano, koristili smo slušalice Mindwave koje su relativno lagane i lako se mogu primijeniti ili skinuti. Također, dizajnirani su da budu slični slušalicama, koje bi trebale proizvesti osjećaj bliskosti i smanjiti samosvijest učenika da ih se nadgleda.

Dva su prepoznatljiva cilja ovog eksperimenta. Jedna je bila prikupljanje različitih moždanih valova i povezanih događaja tijekom aktivnosti rješavanja problema, a druga je bila testiranje mogućnosti korištenja našeg sustava u učionici i mjerenje korisničkog iskustva s aplikacijom i uređajem za EEG snimanje. Kasnije se za klasifikaciju EEG signala predlaže prilagođeni ANN model, što je prikazano na *slici 6.3*



Slika 6.3. Klasifikacija EEG signala

6.5 Opis

Za eksperiment odabrali smo stotinu učenika iz više razreda osnovnih škola (6. i 7. razred) i zabilježili im moždane valove dok su rješavali niz matematičkih zadataka. Na početku eksperimenta učenicima su predstavljene slušalice Mindwave i kratko objašnjenje cijelog procesa. Nakon uvoda zamoljeni su da riješe niz jednostavnih matematičkih problema. Bilo je pet različitih zadataka i u svakom su dobili tri različita odgovora na izbor. Samo je jedan odgovor bio točan, a druga dva lažna, . *slika 6.4.* prikazuje dva učenika tijekom eksperimenta. Tijekom eksperimenta, učenike je cijelo vrijeme nadzirao barem jedan istraživač i dvoje njihovih učitelja, iako nije bilo rizika koji uključuje hardver, jer je cijeli postupak potpuno bezopasan. Slijedeći etička načela istraživanja, učenicima je unaprijed rečeno da će se njihovi moždani valovi zabilježiti te da mogu slobodno birati hoće li sudjelovati ili ne uz pismeno dopuštenje roditelja. Uz to, budući da su još uvijek bili maloljetnici, roditelji su morali dati i njima (i nama) pisanu dozvolu.




Slika 6.4. Učenici osnovne škole koji koriste EEG slušalice tijekom rješavanja matematičkih problema

Osim podataka prikupljenih EEG slušalicama, istraživači su bilježili i sva zanimljiva zapažanja i komentare učenika. Također, tijekom faze rješavanja problema, naša aplikacija zabilježili su sve korisničke događaje, poput odabira jednog odgovora, promjene odabranog odgovora ili učitavanja novog zadatka.


6.6 Pretprocesiranje signala

EEG signali snimljeni su izravno iz NeuroSky Mindwave slušalice. Sirovi EEG signal je pomiješan s puno visokofrekventnog šuma, *slika 6.5*. Ako se sirovi EEG signal ne prerađuje, šum bi imao veliki utjecaj na naknadnu ekstrakciju i prepoznavanje značajki.



Slika 6.5. Sirovi EEG signal

Wavelet domena predstavlja koeficijente razgradnje wavelet transformacije, EEG signal se rastavlja u različitu razinu signala rekonstrukcije pomoću funkcije wavelet db8 [198]. Rezultat metode wavelet potiskivanjem šuma prikazan je na *slika 6.6*.



Slika 6.6. EEG signal nakon potiskivanja šuma.

6.7 Ekstrakcija signala

EEG podaci su snimljeni uz brzinu uzorkovanja od 512 Hz. Za pojednostavnjenje postupka obrade EEG podataka, isti su obrađeni niskopropusnim filtrom frekvencijom odziva od 50 Hz. DWT (eng. discrete wavelet transform) je linearna transformacija koja upravlja vektorskim podacima duljine $2n$, a zatim ih pretvara u nekoliko različitih vektora iste duljine. DWT je metoda za razdvajanje podataka na temelju frekvencije i zatim analizu svakog dijela s rezolucijom koja odgovara ljestvici. DWT se izračunava kaskadom filtra i slijedi 2

poduzorkovanja. U slučaju ove studije odlučili smo upotrijebiti bazu valova Daubechies 8 (Db8). Wavelet je osnova izvedena iz funkcije skaliranja, gdje se skaliranje generira iz procesa razgradnje i rekonstrukcije. Općenito, dekompozicija je postupak ekstrakcije na određenoj frekvenciji, dok rekonstrukcija vraća signal u izvorno stanje. DWT je prikladna metoda za razdvajanje podataka na temelju njihove učestalosti, a zatim analizu svakog dijela s karakteristikama, od kojih svaki signal stvara varijacije koje se razlikuju od emocionalnog stanja ispitanika. EEG signali su u frekvencijskom opsegu (0-4) Hz Delta, (4-8) Hz Theta, (8-12) Hz Alpha, (12-30) Hz Beta, (30-50) Hz Gama. Varijacija frekvencijskih opsega koristi se u odvajanje sirovih podataka. Ova se studija usredotočuje na analizu beta valova jer su ti signali najbliži kada mozak prijeđe iz pasivnog u aktivni način. Diskretna valična transformacija ima veliku prednost pred klasičnim metodama razdvajanja valova. Ona daje optimalnu vremensku i frekvencijsku rezoluciju.

6.8 Gramiano polje kutne razlike (GADF)

Wang i Oates predložili su GADF za pretvaranje vremenskog niza podataka u slike [199]. Postupak kodiranja uključuje normalizaciju ulaznih podataka vremenskih serija u raspon od [-1,1]. Normalizirani ili skalirani signal vremenske serije zatim se pretvara u polarnu koordinatu iz kartezijske koordinate. Ova transformacija zadržava vremenske informacije ulaznog signala. Signal je iskrivljen u domeni pretvorbe. Nakon toga, svaka vremenska točka u polarnim koordinatama uspoređuje se sa svakom drugom točkom za vremensku korelaciju. To se postiže korištenjem trigonometrijske kosinusne funkcije, koja dovodi do Gramijeve matrice dimenzija $[n, n]$, gdje je n broj točaka uzorka EEG vremenske epohe. Neka je $T = \{t_1, \dots, t_n\}$ označava signal s n -uzoraka i T se može skalirati tako da ima interval $[-1,1]$ koji se može definirati;

$$T_0^i = \frac{t_i - \min(T)}{\max(T) - \min(T)} \quad (6.2.)$$

Tada se kut ϕ izračunava pomoću jednadžbe,

$$\Phi = \arccos(T_0^i) \quad (6.3.)$$

Vremenske korelacije susjednih točaka (i, j) izračunavaju se određivanjem zbrajanja kuta, što dovodi do Gramove matrice zvane Gramian Angular Difference Field. To se može zapisati kao,

$$\text{GASF} = [\cos(\varphi_i - \varphi_j)] \quad (6.4.)$$

Ova tehnika može se prilagoditi pretvaranju odabranog uzorka vremenske serije u sliku. Ostale pojedinosti o GADF-u [199].

U ovom radu uzima se 500 EEG uzoraka, što dovodi do slike GADF-a. Kako se uzima u obzir razlika kuta točaka podataka, to dovodi do Gramian Angular diferencijalnog polja. Skup EEG podataka sastoji se od jednokanalnog snimanja EEG signala. EEG signal se dijeli u manje vremenske segmente (brzina uzorkovanja = 512Hz) prema broju učenika i mentalnih zadataka, od 500 uzoraka za izračunavanje GADF-a. Iz EEG podataka dobiva se ukupno 500 GADF slika od toga se 70 % koristi za obuku mreže dubokog učenja.

6.9 Model

Višeslojna neuronska mreža ili višeslojni perceptron (eng. multilayer perceptron) MLP se pretežno koristi u zadacima računalnog vida poput klasifikacija slike. Perceptron, neuronska mreža čije ime dočarava kako je budućnost izgledala iz perspektive 1950-ih, je jednostavan algoritam namijenjen izvođenju binarne klasifikacije; tj. predviđa pripada li unos određenoj kategoriji interesa ili ne: pas ili ne_pas, mačka ili ne_mačka. Perceptron zauzima posebno mjesto u povijesti neuronskih mreža i umjetne inteligencije, jer se početna promocija o izvedbi vodila od strane Minskyja i Paperta [200]. Frank Rosenblatt, kum perceptrona, popularizirao ga je kao uređaj, a ne kao algoritam [201].

Perceptron je linearni klasifikator; odnosno algoritam koji klasificira unos razdvajanjem dviju kategorija ravnom crtom. Ulaz je tipično vektor značajke x pomnožen s težinama w s dodanom pristranošću b : $y = w * x + b$. Perceptron stvara pojedinačni izlaz na temelju nekoliko stvarno vrijednih ulaza formiranjem linearne kombinacije koristeći svoje ulazne težine (i ponekad stvarajući izlaz kroz aktivaciju nelinearne funkcije). Matematička formulacija:

$$y = \Phi(\sum_{i=1}^n w_i x_i + b) = \Phi(w^T x + b) \quad (6.5.)$$

gdje w označava vektor utega, x je vektor ulaza, b je pristranost i Φ je nelinearna aktivacijska funkcija.

Rosenblatt je izgradio jednoslojni perceptron. Odnosno, njegov hardverski algoritam nije obuhvaćao više slojeva, koji omogućuju neuronskim mrežama modeliranje hijerarhije značajki. Bila je to, dakle, plitka neuronska mreža, koja je spriječila njegov perceptron u izvođenju nelinearne klasifikacije, kao što je XOR funkcija *slika. 6.10.* (okidač operatora XOR kad ulaz pokazuje bilo jednu ili drugu osobinu, ali ne i jedno i drugo; stoji za „ekskluzivno ILI ”), Kao što su Minsky i Papert pokazali u svojoj knjizi [200].

XOR

ULAZ x_1	ULAZ x_2	IZLAZ
0	0	0
0	1	1
1	0	1
1	1	0

Slika 6.10. XOR funkcija

Naknadni rad s višeslojnim perceptronima pokazao je da su sposobni aproksimirati XOR operator kao i mnoge druge nelinearne funkcije. Kao što je Rosenblatt temeljio perceptron na McCulloch-Pittsovom neuronu, zamišljenom 1943. godine, tako i sami perceptroni grade blokove koji se pokazuju korisnima samo u tako većim funkcijama kao što su višeslojni perceptroni[202].

Višeslojni perceptron (MLP) je duboka umjetna neuronska mreža. Sastoji se od više perceptrona. Sastoje se od ulaznog sloja za primanje signala, izlaznog sloja koji donosi odluku ili predviđanje o ulaznom signalu, a između ta dva sloja proizvoljan broj skrivenih slojeva koji su pravi računski motor MLP-a.

MLP-ovi s jednim skrivenim slojem mogu aproksimirati bilo koju kontinuiranu funkciju. Višeslojni perceptroni često se primjenjuju na nadgledane probleme učenja. Oni se treniraju na skupu ulazno-izlaznih parova i uče modelirati korelaciju (ili ovisnosti) između tih ulaza i izlaza.

Trening uključuje prilagođavanje parametara ili težine i pristranosti modela kako bi se pogreške svele na najmanju moguću mjeru. Povratno razmnožavanje koristi se za prilagođavanje vaganja i pristranosti u odnosu na pogrešku, a sama se pogreška može izmjeriti na razne načine, uključujući korijensku srednju kvadratnu pogrešku (eng.root-mean-square deviation) RMSE. Mreže poput MLP-a su poput tenisa ili ping ponga. Uglavnom su uključeni u dva pokreta, neprestano naprijed-natrag. Ova usporedba sa ping pong nagađanjima i odgovorima možemo smatrati nekom vrstom ubrzane znanosti, jer je svaka pretpostavka test onoga što mislimo da znamo, a svaki je odgovor povratna informacija koja nam daje do znanja koliko griješimo. U prolazu prema naprijed, protok signala kreće se od ulaznog sloja kroz skrivene slojeve do izlaznog sloja, a odluka izlaznog sloja mjeri se prema osnovnim oznakama istine.

Ova potpuno povezana neuronska mreža analizira konačne vjerojatnosti i odlučuje kojoj klasi pripada slika. Potpuno povezani slojevi izvršavaju klasifikaciju na izvučene značajke na temelju informacija u označenim trening podacima. Svaki čvor u potpuno povezanom sloju povezan je sa svakim čvorom u prethodnom sloju.

6.10 Rezultati

U ovom dijelu su prikazani postignuti eksperimentalni rezultati iz usvojenih pristupa dubokog učenja. U početku se samo EEG signali frekvencijskog opsega od (12-30) Hz tj. Beta područje transformiraju u slike RGB ljestvice pomoću GADF tehnike. Kasnije se pretvorena slika zatim procjenjuje pomoću modela višeslojne neuronske mreže MLP i klasičnih klasifikatora. Primjenjujući postupak GADF-a na EEG podatke vremenskih serija, dobivamo slike GADF-a, koje su prikazane na slici 6.11. Iz ovih slika se može primijetiti da je prostorni uzorak slika GADF-a izrazite i slabe aktivnosti u beta području EEG-a te suptilne promjene u različitom vremenskom trajanju. Također rezultati klasifikacije koji su provedeni na početnim GADF slikama koje odgovaraju EEG zapisu od vremena rješavanja pojedinoga mentalnoga zadatka su vrlo loši. Koristeći se literaturom i istraživanjem znanstvenika Haynesa [203], uvode se promjene u kojima se pojedini signal smanjuje na vrijednost od 20 % od ukupne duljine signala od vremena kada je učenik završio mentalni zadatak. Prema istraživanju Haynesa ljudski mozak desetak sekundi u prosjeku prije odgovora donosi odluku. U tom vremenskom periodu potrebno je istražiti reakciju na mentalni zadatak u vidu EEG signala.

Tada se primjenjuje postupak nove podjele podataka kako bi se dobila EEG slika određenih dimenzije, koja je prikazana na slici 6.12.. Ova slika prikazuje detaljne prostorne značajke GADF-a kod dva suprotno različita EEG signala karakteristična za EEG reakciju kod točnih i netočnih odgovora na mentalne zadatke. Implementirana umjetna neuronska mreže za slike (eng. Image embedding) čita GADF slike i prebacuje ih na udaljeni poslužitelj ili ih lokalno procjenjuje. Za izračunavanje vektora obilježja za svaku sliku koriste se modeli dubokog učenja. Vraća poboljšanu tablicu podataka s dodatnim stupcima (deskriptori slike). Postoji nekoliko ugrađivač mreže za slike (eng. Image embedder), svaki od njih je obučen za određeni zadatak. Slike se šalju na poslužitelj ili se lokalno procjenjuju na korisnikovom računalu, gdje se izračunavaju reprezentacije vektora. SqueezeNet ugrađivač nudi brzu ocjenu na korisničkom računalu koje ne zahtijeva internetsku vezu. U ovom su se radu koristili slijedeći ugrađivači mreže za slike, sa kratkim opisom.

InceptionV3 je Googleova duboka neuronska mreža za prepoznavanje slika. Obučava se na skupu podataka ImageNet. Za ugrađivanje koristimo aktivacije pretposljednog sloja modela koji predstavlja slike s vektorima.

SqueezeNet je duboki model za prepoznavanje slike koji postiže preciznost na razini AlexNet na ImageNetu s 50 puta manjim parametrima. Model je obučen na skupu podataka ImageNet. VGG16 i VGG19 duboke su neuronske mreže za prepoznavanje slike koje je predložila Visual Geometry Group sa Sveučilišta u Oxfordu. Obučeni su na skupu podataka ImageNet.

DeepLoc je konvoluciona mreža obučena na 21.882 slike pojedinačnih stanica koje su ručno dodijeljene jednom od 15 lokalizacijskih odjeljaka. Ugrađivanje je aktiviranje pretposljednog sloja.

Mjerni podaci izvedbe kao što su Precision, Recall i F1-score izračunati su za usporedbu razmatranog ANN modela i za dolje navedene klasifikatore za otkrivanje povezanosti mentalne reakcije u obliku aktivnosti beta valova u EEG području i uspješnosti pri rješavanju mentalnih zadataka. Tablica 6.1. sažima izvedbu modela za mentalnu aktivnost. Mjerni podaci o izvedbi kao što su Preciznost, Odziv i F1-score izračunati su za usporedbu razmatranog ANN modela i klasičnih algoritama kod otkrivanja veze između mentalnoga stanja sa točnim ili netočnim odgovorima prilikom rješavanja zadanih mentalnih zadataka. Izvedba različitih u ovome radu opisanih metoda procjenjuje se izračunavanjem mjernih podataka izvedbe, kako je raspravljeno u literaturi [204]. Dati su izrazi za mjere izvedbe kako slijedi:


$$\text{Preciznost} = T_{+ve} / (T_{+ve} + F_{+ve}) \quad (6.6.)$$

$$\text{Odziv} = \text{Osjetljivost} = T_{+ve} / (T_{+ve} + F_{-ve}) \quad (6.7.)$$

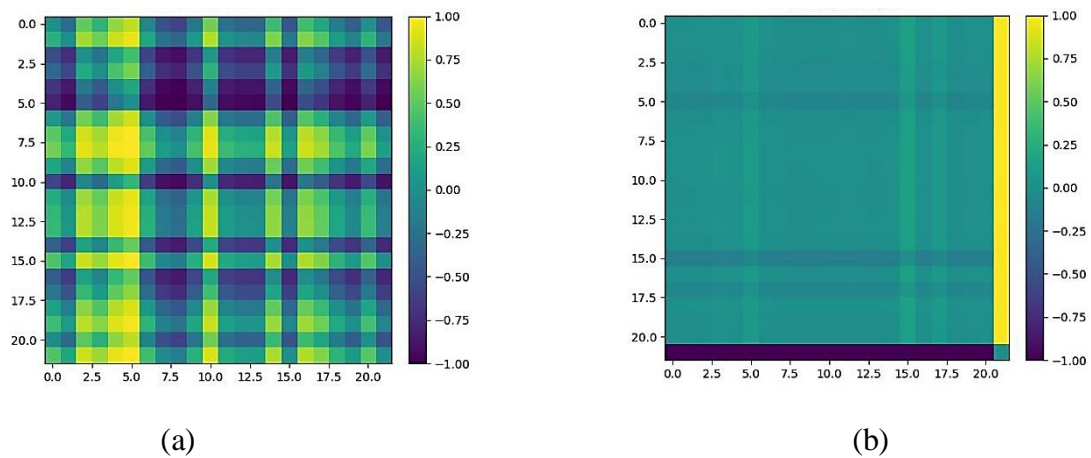
$$F_1 = 2 \left(\frac{\text{Preciznost} * \text{Odziv}}{\text{Preciznost} + \text{Odziv}} \right) \quad (6.8.)$$

gdje T_{-ve} , T_{+ve} , F_{-ve} i F_{+ve} označava istinito-negativno, istinito-pozitivno, lažno negativno i lažno pozitivno. Kada su ove vrijednosti blizu jedinici ili je postotna vrijednost bliže 100, tada je implementirana tehnika najbolji mogući pristup za ispitivanje razmatranog skupa podataka.

Može se primijetiti iz rezultata u *tablici 6.1*, da se za različite Implementacije neuronske mreže za slike ne mijenjaju performanse među korištenim modelima osim kod Random forest klasifikatora.



Slika 6.11. Prikaz GADF slike




Slika 6.12. Prikaz GADF-a

SVM je uz MLP pristup pružio najbolje klasifikacijske performanse u usporedbi s ostalim modelima. Rezultat je pokazao najveću preciznost od 0,808, odziv 0,787 i F1-rezultat 0,786. Štoviše, krivulja radne karakteristike prijarnika ROC (eng. Receiver Operating Characteristic) također je ucrtana za sve modele za ocjenu izvedbe koristeći alternativnu metriku, područje ispod krivulje AUC (eng. Area under the Curve). ROC je grafički prikaz koji ilustrira dijagnostiku sposobnosti sustava binarnog klasifikatora kako varira njegov prag diskriminacije. ROC krivulja stvara se crtanjem istinske pozitivne stope naspram lažno pozitivne stope na različitim postavkama praga. AUC je mjera za određivanje učinkovitosti nekog klasifikatora i jednaka je vjerojatnosti da će klasifikator rangirati slučajno odabrani pozitivan primjer višim nego što će rangirati slučajno odabrani negativan primjer, uz pretpostavku da pozitivni primjeri imaju veći rang. Za idealni klasifikator, vrijednost AUC je '1' i uz slučajno nagađanje uzima vrijednost AUC od 0,5 (daje se kao linearna crta na ROC crtežima prikazanim na *slici 6.13.*). Svi modeli su sa vrijednostima $AUC > 0,5$, što je bolje od slučajnog nagađanja. Međutim, MLP model pružio je najveću vrijednost AUC od 0,876, što je bolje od ostalih modela u usporedbi. Na testiranim skupovima podataka kod MLP klasifikatora treba više skrivenih jedinica, a složenost se kontrolira tako da se broj tih jedinica drži malim, dok složenost SVM-ova ne ovisi o dimenziji skupova podataka. SVM-ovi temeljeni na minimalizaciji strukturnog rizika, dok MLP klasifikatori provode empirijsko minimiziranje rizika. Dakle, SVM-ovi su učinkoviti i generalno su uvijek blizu najbolje klasifikacije jer dobivaju optimalnu površinu za razdvajanje koja ima dobre performanse na prethodno neviđenim podatkovnim točkama. Međutim, glavna razlika je u složenosti mreža. MLP mreža koja provodi globalnu strategiju aproksimacije obično zapošljava vrlo mali broj skrivenih neurona. S druge strane SVM se temelji na lokalnoj strategiji aproksimacije i koristi velik broj skrivenih jedinica. Velika prednost SVM pristupa je formuliranje problema učenja, što dovodi do kvadratnog zadatka optimizacije. To uvelike smanjuje broj operacija u načinu učenja. To se dobro vidi za velike skupove podataka, gdje je SVM algoritam obično puno brži.

Tablica 6.1. Usporedba između višeslojnog perceptorora i klasičnih klasifikatora

	METODA	AUC	CA	F1	PRECIZNOST	ODZIV
SqueezeNet	MLP	0.876	0.793	0.794	0.800	0.793
	Naive Bayes	0.767	0.720	0.720	0.733	0.720
	KNN	0.835	0.753	0.754	0.760	0.753
	Random forest	0.845	0.780	0.780	0.789	0.780
	Logistic regression	0.828	0.733	0.733	0.746	0.733
	SVM	0.835	0.787	0.786	0.808	0.787
	Inception v3	MLP	0.876	0.793	0.794	0.800
Naive Bayes		0.767	0.720	0.720	0.733	0.720
KNN		0.835	0.753	0.754	0.760	0.753
Random forest		0.830	0.800	0.800	0.808	0.800
Logistic regression		0.828	0.733	0.733	0.746	0.733
SVM		0.835	0.787	0.786	0.808	0.787
VGG-19	MLP	0.876	0.793	0.794	0.800	0.793
	Naive Bayes	0.767	0.720	0.720	0.733	0.720
	KNN	0.835	0.753	0.754	0.760	0.753
	Random forest	0.825	0.753	0.754	0.762	0.753
	Logistic regression	0.828	0.733	0.733	0.746	0.733
	SVM	0.835	0.787	0.786	0.808	0.787
DeepLoc	MLP	0.876	0.793	0.794	0.800	0.793
	Naive Bayes	0.767	0.720	0.720	0.733	0.720
	KNN	0.835	0.753	0.754	0.760	0.753
	Random forest	0.825	0.753	0.754	0.762	0.753
	Logistic regression	0.828	0.733	0.733	0.746	0.733
	SVM	0.835	0.787	0.786	0.808	0.787



Slika 6.14. ROC krivulja različitih modela

7. ZAKLJUČAK

Ovim se radom procijenio pristup transformacije EEG-a podataka vremenskih serija na slike pomoću Gramian kutne razlike polja (GADF) za otkrivanje povezanosti mentalne reakcije u vidu EEG zapisa i uspješnosti kod rješavanja mentalnih zadataka. U radu je dat naglasak na prednost korištenja pristupa dubokog učenja u zadacima klasifikacije slika za klasifikaciju EEG signala. Korišteni su različiti modeli pristupa kao što je MLP model te klasični klasifikatori. Također potrebno je naglasiti da su rezultati usko povezani sa određenom skupinom djece, učenika 6 i 7 razreda osnovne škole tako i sa odabirom mentalnih zadataka. Poteškoće koje su nastale na putu do boljih rezultata koji bi otkrili prirodu (ponašanje) EEG signala i njihove povezanosti sa razinom mentalne aktivnosti pa tako i sa razinom tražene kompetencije koja se traži pri rješavanju mentalnih zadataka je nastala zbog kompleksnosti rada i jedinstvenosti svakog pojedinog ljudskog mozga. Proučavanje znanstvenih dostignuća iz polja neuroznanosti je značajno doprinijelo konačnom rezultatu rada. Važno je istaknuti da se tim istraživanjima dokazalo da se ljudski mozak u kratkome periodu od samo nekoliko sekundi prije samoga čina vidljivoga odgovora pri rješavanju mentalnih zadataka već na podsvjesnoj razini donosi odluku. EEG signali kod učenika koji su bili sigurni u točnost svojih odgovora se odlikuju pretežito pojedinačnim ekstremnim skokom vrijednosti signala u beta području. Intuitivno se naslučuje da se većim uvjerenjem učenika u točnost riješenog zadatka odlikuje EEG signalima, odnosno GADF slikama karakterističnima za takav ishod. Suprotno, učenici koji nisu bili dovoljno sigurni u točnost riješenoga zadatka ili su prema izlaznim EEG signalima na neki način previše „sumnjali“ u svoje znanje ili se propitivali do konačnoga odgovora iskazuju nedovoljno znanje, upitnu kompetenciju za rješavanje mentalnog zadatka a time i svojstvene GADF slike. Jednostavni, pristupačni i praktični EEG uređaj koji se koristio za prikupljanje podataka je koristan u strogo definiranoj i prilagođenoj okolini. Uz postojeće algoritme za koncentraciju i meditaciju te prilagodbi sustava za prepoznavanje mentalnog stanja prvenstveno učenika u učionici, otvara se mogućnost da se isti sustav koristi kao dodatak nastavi.

LITERATURA

- [1] A. Furdea, S. Halder, D. J. Krusienski, D. Bross, F. Nijboer, N. Birbaumer, and A. Kübler. 2009. An auditory oddball (P300) spelling system for brain-computer interfaces. *Psychophysiology* 46, 3 (2009), 617–625.
- [2] Andrea Kübler, Adrian Furdea, Sebastian Halder, Eva Maria Hammer, Femke Nijboer, and Boris Kotchoubey. 2009. A brain–computer interface controlled auditory event-related potential (P300) spelling system for locked-in patients. *Annals of the New York Academy of Sciences* 1157, 1 (2009), 90–100
- [3] Sebastian Halder, Andreas Pinegger, Ivo Käthner, Selina C. Wriessnegger, Josef Faller, João B. Pires Antunes, Gernot R. Müller-Putz, and Andrea Kübler. 2015. Brain-controlled applications using dynamic P300 speller matrices. *Artificial Intelligence in Medicine* 63, 1 (2015), 7–17
- [4] N. Birbaumer, A. Kubler, N. Ghanayim, T. Hinterberger, J. Perelmouter, J. Kaiser, I. Iversen, B. Kotchoubey, N. Neumann, and H. Flor. 2000. The thought translation device (TTD) for completely paralyzed patients. *IEEE Transactions on Rehabilitation Engineering* 8, 2 (Jun 2000), 190–193.
- [5] Jeanny Herault, Christian Jutten, and John S. Denker. 1986. Space or time adaptive signal processing by neuralnetwork models. In *AIP Conference Proceedings*, Vol. 151. AIP, 206–211
- [6] Zoltan J. Koles, Michael S. Lazar, and Steven Z. Zhou. 1990. Spatial patterns underlying population differences inthe background EEG. *Brain Topography* 2, 4 (1990), 275–284
- [7] Karl Pearson. 1901. LIII. On lines and planes of closest fit to systems of points in space. *The London, Edinburgh, andDublin Philosophical Magazine and Journal of Science* 2, 11 (1901), 559–572.
- [8] Stephane G. Mallat. 1989. A theory for multiresolution signal decomposition: The wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 11, 7 (1989), 674–693.
- [9] Ronald A. Fisher. 1936. The use of multiple measurements in taxonomic problems. *Annals of Eugenics* 7, 2 (1936), 179–188.
- [10] Corinna Cortes and Vladimir Vapnik. 1995. Support-vector networks. *Machine Learning* 20, 3 (1995), 273–297.

- [11] Warren S. McCulloch and Walter Pitts. 1943. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics* 5, 4 (1943), 115–133.
- [12] L. A. Zadeh. 1965. Fuzzy sets. *Information and Control* 8, 3 (1965), 338–353.
- [13] Berger, H.: *Über das Elektrenkephalogramm des Menschen*. *Archiv. Psychiatrie. und. Nervenkrankheiten*. 87, 527–570 (1929)
- [14] Bear, M.F., Connors, B.W., Paradiso, M.A.: *Neuroscience: Exploring the Brain*. Lippincott, Philadelphia (2006)
- [15] Paszkiel, S.: Concept of expert system interpreting correctness of measurement and method of the EEG signal analysis for needs of the brain-computer interface. *Poznań Univ. Technol. Acad.J. Electr. Eng.* 88, 209–216 (2016). ISSN 1897-0737
- [16] Ovaysikia, S., Tahir, K.A., Chan, J.L., DeSouza, J.F.X.: Wordwinsoverface: Emotional stroop effect activates the frontal cortical network. *Front. Hum. Neurosci.* (2011).
- [17] Paszkiel, S.: The population modeling of neuronal cell fractions for the use of controlling amobile robot. In: *Measurements Robotics Automation—P A R*, 2/2013, Warszawa, pp. 254–259 (2013)
- [18] Badcock, N.A. et al.: Validation of the Emotiv EPOC EEG system for research quality auditory event-related potentials in children. *Peer J.* 907 (2015).
- [19] Rabie A. Ramadan and Athanasios V. Vasilakos. 2017. Brain computer interface: Control signals review. *Neurocomputing* 223 (2017), 26–44
- [20] Raymundo Cassani, Tiago H. Falk, Francisco J. Fraga, Marco Cecchi, Dennis K. Moore, and Renato Anghinah. 2017. Towards automated electroencephalography-based Alzheimer’s disease diagnosis using portable low-density devices. *Biomedical Signal Processing and Control* 33 (2017), 261–271.
- [21] Wilhelm Von Rosenberg, Theerasak Chanwimalueang, Valentin Goverdovsky, David Looney, David Sharp, and Danilo P. Mandic. 2016. Smart helmet: Wearable multichannel ECG and EEG. *IEEE Journal of Translational Engineering in Health and Medicine* 4 (2016) 1–11.
- [22] A. Bertrand and M. Moonen, "Distributed eye blink artifact removal in a wireless EEG sensor network," 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Florence, 2014, pp. 5849-5853,
- [23] Peter J. Uhlhaas, Peter Liddle, David Linden, Anna C. Nobre, Krish D. Singh, and Joachim Gross. 2017. Magnetoencephalography as a tool in psychiatric research: Current status and perspective. *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging* (2017).

- [24] David Cohen. 1972. Magnetoencephalography: detection of the brain's electrical activity with a superconducting magnetometer. *Science* 175, 4022 (1972), 664–666.
- [25] Hubert Cecotti. 2016. Single-trial detection with magnetoencephalography during a dual-rapid serial visual presentation task. *IEEE Transactions on Biomedical Engineering* 63, 1 (2016), 220–227.
- [26] Franca Tecchio, Francesca Benassi, Filippo Zappasodi, Leonardo Emberti Gialloreti, Mark Palermo, Stefano Seri, and Paolo Maria Rossini. 2003. Auditory sensory processing in autism: A magnetoencephalographic study. *Biological Psychiatry* 54, 6 (2003), 647–654
- [27] Naja Ferjan Ramírez, Rey R. Ramírez, Maggie Clarke, Samu Taulu, and Patricia K. Kuhl. 2017. Speech discrimination in 11-month-old bilingual and monolingual infants: a magnetoencephalography study. *Developmental Science* 20, 1 (2017), e12427.
- [28] Talitha C. Ford, Will Woods, and David P. Crewther. 2018. Magnetoencephalography reveals an increased nontarget P3a, but not target P3b, that is associated with high non-clinical psychosocial deficits. *Psychiatry Research: Neuroimaging* 271 (2018), 1–7. DOI:<https://doi.org/10.1016/j.psychresns.2017.11.012>
- [29] P. Rinck. 2014. Magnetic resonance: A critical peer-reviewed introduction. In *Magnetic Resonance in Medicine. The Basic Textbook of the European Magnetic Resonance forum* (8th. ed.). <http://www.magnetic-resonance.org/ch/21-01.html>.
- [30] Ranganatha Sitaram, Nikolaus Weiskopf, Andrea Caria, Ralf Veit, Michael Erb, and Niels Birbaumer. 2008. fMRI brain-computer interfaces. *IEEE Signal Processing Magazine* 25, 1 (2008), 95–106.
- [31] Anna Martin, Matthias Schurz, Martin Kronbichler, and Fabio Richlan. 2015. Reading in the brain of children and adults: A meta-analysis of 40 functional magnetic resonance imaging studies. *Human Brain Mapping* 36, 5 (2015), 1963–1981.
- [32] Vincent J. Schmithorst, Scott K. Holland, and Elena Plante. 2007. Object identification and lexical/semantic access in children: A functional magnetic resonance imaging study of word-picture matching. *Human Brain Mapping* 28, 10 (2007), 1060–1074.
- [33] Charlotte Herzmann, Leire Zubiaurre-Elorza, Conor J. Wild, Annika C. Linke, Victor K. Han, David S. C. Lee, and Rhodri Cusack. 2017. Using functional magnetic resonance imaging to detect preserved function in a preterm infant with brain injury. *The Journal of Pediatrics* 189 (2017), 213–217.

- [34] Niels Janssen, Juan A. Hernández-Cabrera, and Laura Ezama Foronda. 2018. Improving the signal detection accuracy of functional magnetic resonance imaging. *NeuroImage* 176 (2018), 92–109.
- [35] Valente, G., Kaas, A.L., Formisano, E., Goebel, R.: Optimizing fMRI experimental design for MVPA-based BCI control: combining the strengths of block and event-related designs. *NeuroImage* 186, 369–381 (2019).
- [36] J. Malmivuo Comparison of the properties of EEG and MEG in detecting the electric activity of the brain *Brain Topogr.*, 25 (2012), pp. 1-19
- [37] S.P. Ahlfors, J. Han, J.W. Belliveau, M.S. Hämäläinen Sensitivity of MEG and EEG to source orientation *Brain Topogr.*, 23 (2010), pp. 227-232
- [38] D. Cohen, B.N. Cuffin, K. Yunokuchi, R. Maniewski, C. Purcell, G.R. Cosgrove, J. Ives, J.G. Kennedy, D.L. Schomer MEG versus EEG localization test using implanted sources in the human brain *Ann. Neurol.*, 28 (1990), pp. 811-817
- [39] R. Hari *Magnetoencephalography: methods and applications* D.L. Schomer, F.H. Lopes da Silva (Eds.), *Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications and Related Fields* (6th Edition), Lippincott Williams & Wilkins, Philadelphia (2011), pp. 865-900
- [40] Lopes da Silva F. *Neuron*. 2013 Dec 4;80(5):1112-28.
- [41] M. Bishop, "Introduction," in *Pattern Recognition and Machine Learning*, pp. 1–4, Springer-Verlag New York, Inc., 2006.
- [42] P. Viola, O. M. Way, and M. J. Jones, "Robust Real-Time Face Detection," *International Journal of Computer Vision*, vol. 57, no. 2, pp. 137–154, 2004.
- [43] M. Bishop, *Pattern Recognition and Machine Learning*. Springer-Verlag New York, Inc., 2006.
- [44] F. Lotte and M. Congedo, "A Review of Classification Algorithms for EEG-based Brain-Computer Interfaces," *Journal of Neural Engineering*, vol. 4, pp. 1–24, 2007
- [45] Schlögl A, Vidaurre C and Müller K R 2010 Adaptive methods in BCI research-an introductory tutorial *Brain-Computer Interfaces* (Berlin: Springer) pp 331–55
- [46] Shenoy P, Krauledat M, Blankertz B, Rao R and Müller K R 2006 Towards adaptive classification for BCI *J. Neural Eng.* 3 R13
- [47] Butfield A, Ferrez P and Millan J 2006 Towards a robust BCI: error potentials and online learning *IEEE Trans. Neural Syst. Rehabil. Eng.* 14 164–8
- [48] Gan J 2006 Self-adapting BCI based on unsupervised learning 3rd Int. Brain-Computer Interface Workshop

- [49] Millán J, Renkens F, Mouriño J and Gerstner W 2004 Noninvasive brain-actuated control of a mobile robot by human EEG *IEEE Trans. Biomed. Eng.* 51 1026–33
- [50] Sykacek P, Roberts S J and Stokes M 2004 Adaptive BCI based on variational bayesian kalman filtering: an empirical evaluation *IEEE Trans. Biomed. Eng.* 51 719–29
- [51] Kindermans P J, Schreuder M, Schrauwen B, Müller K R and Tangermann M 2014 Improving zero-training brain–computer interfaces by mixing model estimators *PloS One* 9 e102504
- [52] Blumberg J, Rickert J, Waldert S, Schulze-Bonhage A, Aertsen A and Mehring C 2007 Adaptive classification for brain computer interfaces 29th Annual Int. Conf. of the IEEE Engineering in Medicine and Biology Society pp 2536–9
- [53] Vidaurre C, Kawanabe M, Von Bunau P, Blankertz B and Muller K 2011 Toward unsupervised adaptation of LDA for brain–computer interfaces *IEEE Trans. Biomed. Eng.* 58 587–97
- [54] Zanini P, Congedo M, Jutten C, Said S and Berthoumieu Y 2017 Transfer learning: a Riemannian geometry framework with applications to brain–computer interfaces *IEEE Trans. Biomed. Eng.*
- [55] Li Y and Guan C 2008 Joint feature re-extraction and classification using an iterative semi-supervised support vector machine algorithm *Mach. Learn.* 71 33–53
- [56] Li Y, Guan C, Li H and Chin Z 2008 A self-training semisupervised SVM algorithm and its application in an EEGbased brain computer interface speller system *Pattern Recogn.Lett.* 29 1285–94
- [57] Congedo M, Barachant A and Bhatia R 2017 Riemannian geometry for EEG-based brain–computer interfaces; a primer and a review *Brain-Comput. Interfaces* 4 155–74 [55] Li Y and Guan C 2008 Joint feature re-extraction and classification using an iterative semi-supervised support vector machine algorithm *Mach. Learn.* 71 33–53
- [58] Yger F, Berar M and Lotte F 2017 Riemannian approaches in brain–computer interfaces: a review *IEEE Trans. Neural Syst. Rehabil. Eng.* 25 1753–62
- [59] Bhatia R 2009 *Positive Definite Matrices* (Princeton, NJ: Princeton University Press)
- [60] Edelman A, Tomás A and Smith S T 1998 The geometry of algorithms with orthogonality constraints *SIAM J. Matrix Anal. Appl.* 20 303–53
- [61] Absil P A, Mahony R and Sepulchre R 2009 *Optimization Algorithms on Matrix Manifolds* (Princeton, NJ: Princeton University Press)
- [62] Long M, Wang J, Ding G, Sun J and Yu P S 2013 Transfer feature learning with joint distribution adaptation *Proc. Of the IEEE Int. Conf. on Computer Vision* pp 2200–7

- [63] Si S, Tao D and Geng B 2010 Bregman divergence-based regularization for transfer subspace learning *IEEE Trans. Knowl. Data Eng.* 22 929–42
- [64] Sugiyama M, Nakajima S, Kashima H, Buenau P V and Kawanabe M 2008 Direct importance estimation with model selection and its application to covariate shift adaptation *Advances in Neural Information Processing Systems* pp 1433–40
- [65] Daumé H III 2007 Frustratingly easy domain adaptation *Proc. of the Association Computational Linguistics*
- [66] Pan S J and Yang Q 2010 A survey on transfer learning *IEEE Trans. Knowl. Data Eng.* 22 1345–59
- [67] Gong B, Shi Y, Sha F and Grauman K 2012 Geodesic flow kernel for unsupervised domain adaptation *IEEE Conf. On Computer Vision and Pattern Recognition* pp 2066–73
- [68] Zhang K, Zheng V, Wang Q, Kwok J, Yang Q and Marsic I 2013 Covariate shift in hilbert space: a solution via sorrogate kernels *Int. Conference on Machine Learning* pp 388–95
- [69] Courty N, Flamary R, Tuia D and Rakotomamonjy A 2017 Optimal transport for domain adaptation *IEEE Trans. Pattern Anal. Mach. Intell.* 39 1853–65
- [70] Li S Z 2009 *Markov Random Field Modeling in Image Analysis* (Berlin: Springer)
- [71] Fischer A and Igel C 2012 An introduction to restricted Boltzmann machines *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications, CIARP 2012, Lecture Notes in Computer Science* vol 7441, ed L Alvarez, M Mejail, L Gomez, J Jacabo (Berlin: Springer) pp 14–36
- [72] Hinton G E, Osindero S and Teh Y W 2006 A fast learning algorithm for deep belief nets *Neural Comput.* 18 1527–54
- [73] Hinton G E 2002 Training products of experts by minimizing contrastive divergence *Neural Comput.* 14 1771–800
- [74] Bengio Y, Lamblin P, Popovici D and Larochelle H 2007 Greedy layer-wise training of deep networks *Advances in Neural Information Processing Systems* pp 153–60
- [75] Tieleman T 2008 Training restricted boltzmann machines using approximations to the likelihood gradient *Proc.. of the 25th Int. Conf. on Machine Learning (ACM)* pp 1064–71
- [76] McCorduck, P. (2004). *Machines Who Think*, 2nd Edn. Natick, MA: A. K. Peters, Ltd.
- [77] Dayan, P., and Abbott, L. F. (2005). *Theoretical Neuroscience*. Cambridge, MA: MIT Press.
- [78] Chang, E. F. (2015). Towards large-scale, human-based, mesoscopic neurotechnologies. *Neuron* 86, 68–78.

- [79] Jordan, M. I., and Mitchell, T. M. (2015). Machine learning: trends, perspectives, and prospects. *Science* 349, 255–260.
- [80] Gershman, S. J., Horvitz, E. J., and Tenenbaum, J. B. (2015). Computational rationality: a converging paradigm for intelligence in brains, minds, and machines. *Science* 349, 273–278.
- [81] Braitenberg, V. (1986). *Vehicles: Experiments in Synthetic Psychology*. Cambridge, MA: The MIT Press.
- [82] Hassabis, D., Kumaran, D., Summerfield, C., and Botvinick, M. (2017). Neuroscience-inspired artificial intelligence. *Neuron* 95, 245–258.
- [83] Griffiths, T., Chater, N., and Kemp, C. (2010). Probabilistic models of cognition: exploring representations and inductive biases. *Trends Cogn. Sci.* 14, 357–364.
- [84] Jaynes, E. (1988). How does the brain do plausible reasoning? *Maximum Entropy Bayesian Methods Sci. Eng.* 1, 1–24. Koller, D., and Friedman, N. (2009). *Probabilistic Graphical Models: Principles and Techniques*. Cambridge, MA: The MIT Press.
- [85] Koller, D., and Friedman, N. (2009). *Probabilistic Graphical Models: Principles and Techniques*. Cambridge, MA: The MIT Press.
- [86] Blei, D. M., Ng, A. Y., and Jordan, M. I. (2003). Latent dirichlet allocation. *J. Mach. Learn. Res.* 3, 993–1022.
- [87] Marblestone, A. H., Wayne, G., and Kording, K. P. (2016). Towards an integration of deep learning and neuroscience. *Front. Comput. Neurosci.* 10:94.
- [88] Widrow, B., and Lehr, M. A. (1990). 30 Years of adaptive neural networks: perceptron, madaline, and backpropagation. *Proc. IEEE* 78, 1415–1442.
- [89] Miconi, T. (2017). Biologically plausible learning in recurrent neural networks for flexible decision tasks. *Elife* 6:e20899.
- [90] Roelfsema, P. R., and van Ooyen, A. (2005). Attention-gated reinforcement learning of internal representations for classification. *Neural Comput.* 17, 2176–2214.
- [91] Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychol. Rev.* 65, 386–408.
- [92] van Gerven, M. A. J. (2017). A primer on encoding models in sensory neuroscience. *J. Math. Psychol.* 76, 172–183.
- [93] Minsky, M., and Papert, S. (1969). *Perceptrons. An Introduction to Computational Geometry*. Cambridge, MA: MIT Press.
- [94] Rumelhart, D., Hinton, G., and Williams, R. (1986). “Learning internal representations by error propagation,” in *Parallel Distributed Processing, Explorations in the Microstructure*

- of Cognition, eds D. E. Rumelhart and J. L. McClelland (Cambridge, MA: MIT Press), 318–362
- [95] Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Math. Control Signals Syst.* 2, 303–314.
- [96] Simon, H. A. (1962). The architecture of complexity. *Proc. Am. Philos. Soc.* 106, 467–482. doi: 10.1007/978-1-4899-0718-9_31
- [97] Felleman, D. J., and Van Essen, D. C. (1991). Distributed hierarchical processing in the primate cerebral cortex. *Cereb. Cortex* 1, 1–47.
- [98] Badre, D. (2008). Cognitive control, hierarchy, and the rostro-caudal organization of the frontal lobes. *Trends Cogn. Sci.* 12, 193–200.
- [99] Swanson, L. W. (2000). Cerebral hemisphere regulation of motivated behavior. *Brain Res.* 886, 113–164.
- [100] Minsky, M., and Papert, S. (1969). *Perceptrons. An Introduction to Computational Geometry.* Cambridge, MA: MIT Press.
- [101] LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature* 521, 436–444.
- [102] Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). “ImageNet classification with deep convolutional neural networks,” in *Advances in Neural Information Processing Systems 25 (Lake Tahoe)*, 1106–1114.
- [103] Singer, W. (2013). Cortical dynamics revisited. *Trends Cogn. Sci.* 17, 616–626.
- [104] Maass, W. (2016). Searching for principles of brain computation. *BioRxiv*, 1–16.
- [105] Jordan, M. I. (1987). “Attractor dynamics and parallelism in a connectionist sequential machine,” in *Proceedings of the Eighth Annual Conference of the Cognitive Science Society*, 531–546
- [106] Elman, J. L. (1990). Finding structure in time. *Cogn. Sci.* 14, 179–211.
- [107] Dayan, P., and Abbott, L. F. (2005). *Theoretical Neuroscience.* Cambridge, MA: MIT Press
- [108] Funahashi, K.-I., and Nakamura, Y. (1993). Approximation of dynamical systems by continuous time recurrent neural networks. *Neural Netw.* 6, 801–806.
- [109] Mozer, M. C. (1989). A focused back-propagation algorithm for temporal pattern recognition. *Complex Syst.* 3, 349–381.
- [110] Thorpe, S. J., and Fabre-Thorpe, M. (2001). Seeking categories in the brain. *Science* 291, 260–262.
- [111] Vanrullen, R. (2007). The power of the feed-forward sweep. *Adv. Cogn. Psychol.* 3, 167–176.

- [112] Joukes, J., Hartmann, T. S., and Krekelberg, B. (2014). Motion detection based on recurrent network dynamics. *Front. Syst. Neurosci.* 8:239.
- [113] Gilbert, C. D., and Li, W. (2013). Top-down influences on visual processing. *Nat. Rev. Neurosci.* 14, 350–363.
- [114] Willshaw, D. J., Dayan, P., and Morris, R. G. M. (2015). Memory, modelling and Marr: a commentary on Marr (1971) ‘Simple memory: A theory of archicortex’. *Philos. Trans. R. Soc. B* 370:20140383.
- [115] Kumaran, D., Hassabis, D., and McClelland, J. L. (2016). What learning systems do intelligent agents need? Complementary learning systems theory updated. *Trends Cogn. Sci.* 20, 512–534.
- [116] Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proc. Natl. Acad. Sci. U.S.A.* 79, 2554–2558.
- [117] Wills, T. J., Lever, C., Cacucci, F., Burgess, N., and Keefe, J. O. (2005). Attractor dynamics in the hippocampal representation of the local environment. *Science* 308, 873–876.
- [118] Crick, F., and Mitchison, G. (1983). The function of dream sleep. *Nature* 304, 111–114.
- [119] Sutton, R. S., and Barto, A. G. (1998). *Reinforcement Learning: An Introduction*. Cambridge, MA: MIT Press.
- [120] Daw, N. D. (2012). “Model-based reinforcement learning as cognitive search: neurocomputational theories,” in *Cognitive Search: Evolution, Algorithms, and the Brain*, eds P. M. Todd, T. T. Hills, and T. W. Robbins (Cambridge, MA: The MIT Press), 195–208.
- [121] Buschman, T. J., Miller, E. K., and Miller, E. K. (2014). Goal-direction and top-down control. *Philos. Trans. R. Soc. B* 369, 1–9.
- [122] Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., et al. (2015). Human-level control through deep reinforcement learning. *Nature* 518, 529–533.
- [123] Silver, D., Schrittwieser, J., Simonyan, K., Antonoglou, I., Huang, A., Guez, A., et al. (2017). Mastering the game of Go without human knowledge. *Nature* 550, 354–359.
- [124] Silver, D., Lever, G., Heess, N., Degris, T., Wierstra, D., and Riedmiller, M. (2014). “Deterministic policy gradient algorithms,” in *2nd International Conference on Learning Representations (Banff)*, 387–395.
- [125] Schulman, J., Levine, S., Moritz, P., Jordan, M., and Abbeel, P. (2015). Trust region policy optimization. *ArXiv:1502.05477v4*, 1–16

- [126] Salimans, T., Ho, J., Chen, X., and Sutskever, I. (2017). Evolution strategies as a scalable alternative to reinforcement learning. *ArXiv:1703.03864v2*, 1–12
- [127] Whitehead, S. D., and Ballard, D. H. (1991). Learning to perceive and act by trial and error. *Mach. Learn.* 7, 45–83.
- [128] Moser, M.-B., Rowland, D. C., and Moser, E. I. (2015). Place cells, grid cells, and memory. *Cold Spring Harb. Perspect. Biol.* 7:a021808
- [129] Kanitscheider, I., and Fiete, I. (2016). Training recurrent networks to generate hypotheses about how the brain solves hard navigation problems. *ArXiv:1609.09059*, 1–10.
- [130] Song, H. F., Yang, G. R., and Wang, X.-J. (2016). Reward-based training of recurrent neural networks for diverse cognitive and value-based tasks. *Elife* 6, 1–51.
- [131] Lee, T., and Mumford, D. (2003). Hierarchical Bayesian inference in the visual cortex. *J. Opt. Soc. Am. A* 20, 1434–1448.
- [132] Yuille, A., and Kersten, D. (2006). Vision as Bayesian inference: analysis by synthesis? *Trends Cogn. Sci.* 10, 301–308.
- [133] Clark, A. (2013). Whatever next? Predictive brains, situated agents, and the future of cognitive science. *Behav. Brain Sci.* 36, 181–204.
- [134] Summerfield, C., and de Lange, F. P. (2014). Expectation in perceptual decision making: neural and computational mechanisms. *Nat. Rev. Neurosci.* 15, 745–756.
- [135] Hatfield, G. (2002). “Perception and the physical world: psychological and philosophical issues in perception,” in *Perception and the Physical World: Psychological and Philosophical Issues in Perception*, eds D. Heyer and R. Mausfeld (Hoboken, NJ: John Wiley and Sons), 113–143.
- [136] Doya, K., Ishii, S., Pouget, A., and Rao, R. P. N. (eds.). (2006). *Bayesian Brain: Probabilistic Approaches to Neural Coding*. Cambridge, MA: The MIT Press
- [137] Friston, K. J. (2010). The free-energy principle: a unified brain theory? *Nat. Rev. Neurosci.* 11, 127–138.
- [138] Schacter, D. L., Addis, D. R., and Buckner, R. L. (2007). Remembering the past to imagine the future: the prospective brain. *Nat. Rev. Neurosci.* 8, 657–661.
- [139] Moulton, S. T., and Kosslyn, S. M. (2009). Imagining predictions: mental imagery as mental emulation. *Philos. Trans. R. Soc. B* 364, 1273–1280.
- [140] Corneil, D., and Gerstner, W. (2015). “Attractor network dynamics enable preplay and rapid path planning in maze-like environments,” in *Advances in Neural Information Processing Systems 28* (Montreal), 1–9.

- [141] Dragoi, G., and Tonegawa, S. (2011). Hippocampal cellular assemblies. *Nature* 469,397–401.
- [142] Ashby, W. (1952). *Design for a Brain*. London: Chapman & Hall.
- [143] Todorov, E., and Jordan, M. I. (2002). Optimal feedback control as a theory of motor coordination. *Nat. Neurosci.* 5, 1226–1235.
- [144] Rao, R. P. and Ballard, D. H. (1999). Predictive coding in the visual cortex: a functional interpretation of some extra-classical receptive-field effects. *Nat. Neurosci.* 2, 79–87.
- [145] Huang, Y., and Rao, R. P. N. (2011). Predictive coding. *WIREs Cogn. Sci.* 2,580–593.
- [146] Hinton, G. (2013). Where do features come from? *Cogn. Sci.* 38, 1078–1101.
- [147] Hinton, G. E., and Sejnowski, T. J. (1983). “Optimal perceptual inference,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (Washington, DC).
- [148] Ackley, D., Hinton, G. E., and Sejnowski, T. (1985). A learning algorithm for Boltzmann machines. *Cogn. Sci.* 9, 147–169.
- [149] Dayan, P., Hinton, G. E., Neal, R., and Zemel, R. (1995). The Helmholtz machine. *Neural Comput.* 7, 1–16.
- [150] Hinton, G. E., Osindero, S., and Teh, Y. (2006). A fast learning algorithm for deep belief nets. *Neural Comput.* 18, 1527–1554.
- [151] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., et al. (2014). Generative adversarial nets. *ArXiv:1406.2661v1*, 1–9
- [152] Lotter, W., Kreiman, G., and Cox, D. (2016). Deep predictive coding networks for video prediction and unsupervised learning. *ArXiv:1605.08104*, 1–12.
- [153] Mathieu, M., Couprie, C., and LeCun, Y. (2016). “Deep multi-scale video prediction beyond mean square error,” in *4th International Conference on Learning Representations* (San Juan), 1–14
- [154] Xue, T., Wu, J., Bouman, K. L., and Freeman, W. T. (2016). Visual dynamics: probabilistic future frame synthesis via cross convolutional networks. *ArXiv:1607.02586*, 1–11.
- [155] Pinker, S., and Mehler, J. (eds.). (1988). *Connections and Symbols*. Cambridge, MA: The MIT Press.
- [156] Graves, A., Wayne, G., and Danihelka, I. (2014). Neural Turing machines. *ArXiv:1410.5401*, 1–26.
- [157] Fodor, J. A., and Pylyshyn, Z. W. (1988). Connectionism and cognitive architecture: a critical analysis. *Cognition* 28, 3–71.

- [158] Bordes, A., Chopra, S., and Weston, J. (2015). Large-scale simple question answering with memory networks. *ArXiv:1506.02075v1*, 1–10.
- [159] Agrawal, A., Lu, J., Antol, S., Mitchell, M., Zitnick, C. L., Batra, D., et al. (2016). VQA: visual question answering. *ArXiv:1505.00468*, 1–25
- [160] Tapaswi, M., Zhu, Y., Stiefelhagen, R., Torralba, A., Urtasun, R., and Fidler, S. (2015). MovieQA: understanding stories in movies through question answering. *ArXiv:1512.02902*, 1–10.
- [161] Johnson, J., Hariharan, B., van der Maaten, L., Hoffman, J., Fei-Fei, L., Zitnick, C. L., et al. (2017). Inferring and executing programs for visual reasoning. *ArXiv:1705.03633*.
- [162] Yang, G. R., Song, H. F., Newsome, W. T., and Wang, X. (2017). Clustering and compositionality of task representations in a neural network trained to perform many cognitive tasks. *BioRXiv*, 1–44.
- [163] Mikolov, T., Chen, K., Corrado, G., and Dean, J. (2013). “Efficient estimation of word representations in vector space,” in 1st International Conference on Learning Representations (Scottsdale).
- [164] Ferrone, L., and Zanzotto, F. M. (2017). Symbolic, distributed and distributional representations for natural language processing in the era of deep learning: survey. *ArXiv:1702.00764*, 1–25.
- [165] Kemp, C., and Tenenbaum, J. B. (2008). The discovery of structural form. *Proc. Natl. Acad. Sci. U.S.A.* 105:10687.
- [166] Lake, B. M., Ullman, T. D., Tenenbaum, J. B., and Gershman, S. J. (2017). Building machines that learn and think like people. *Behav. Brain Sci.*
- [167] Brachman, R. J. (2002). Systems that know what they’re doing. *IEEE Intell. Syst.* 17,67–71.
- [168] Louizos, C., Shalit, U., Mooij, J., Sontag, D., Zemel, R., and Welling, M. (2017). Causal effect inference with deep latent-variable models. *ArXiv:1705.08821*, 1–12.
- [169] Santoro, A., Raposo, D., Barrett, D. G. T., Malinowski, M., Pascanu, R., Battaglia, P., et al. (2017). A simple neural network module for relational reasoning. *ArXiv:1706.01427v1*, 1–16.
- [170] Zhu, Y., Gordon, D., Kolve, E., and Fox, D. (2017). Visual semantic planning using deep successor representations. *ArXiv:1705.08080v1*, 1–13. *ArXiv:1706.01427v1*, 1–16.
- [171] Wain, “Lifelong education,” *Encyclopedia of educational theory and philosophy*. SAGE Publications, pp. 482–484, 2014.

- [172] C.-M. Chen, "Intelligent web-based learning system with personalized learning path guidance," *Comput. Educ.*, vol. 51, pp. 787–814, 2008.
- [173] J. R. van Seters, M. A. Ossevoort, J. Tramper, and M. J. Goedhart, "The influence of student characteristics on the use of adaptive e-learning material," *Comput. Educ.*, vol. 58, no. 3, pp. 942–952, Apr. 2012
- [174] HanoverResearch, "2016 TRENDS IN HIGHER EDUCATION MARKETING, ENROLLMENT, AND TECHNOLOGY," Hanover, 2015.
- [175] D. F. O. Onah, J. Sinclair, and R. Boyatt, "Dropout rates of massive open online courses: behavioural patterns," *EDULEARN14 Proc.*, pp. 5825–5834, 2014.
- [176] K. Loibl and N. Rummel, "Knowing what you don't know makes failure productive," *Learn. Instr.*, vol. 34, pp. 74–85, Dec. 2014.
- [177] P. J. Denning and G. Flores, "The Profession of IT Learning to Learn," *Commun. ACM*, vol. 59, no. 12, pp. 32–36, 2016.
- [178] J. C. Cassady and R. E. Johnson, "Cognitive Test Anxiety and Academic Performance," *Contemp. Educ. Psychol.*, vol. 27, no. 2, pp. 270–295, Apr. 2002.
- [179] M. S. Chapell et al., "Test Anxiety and Academic Performance in Undergraduate and Graduate Students.," *J. Educ. Psychol.*, vol. 97, no. 2, pp. 268–274, 2005.
- [180] F. G. DordiNejad et al., "On the relationship between test anxiety and academic performance," *Procedia - Soc. Behav. Sci.*, vol. 15, pp. 3774–3778, Jan. 2011.
- [181] S. Bonaccio, C. L. Reeve, and E. C. Winford, "Text anxiety on cognitive ability test can result in differential predictive validity of academic performance," *Pers. Individ. Dif.*, vol. 52, no. 4, pp. 497–502, Mar. 2012.
- [182] M. Sommer and M. E. Arendasy, "Comparing different explanations of the effect of test anxiety on respondents' test scores," *Intelligence*, vol. 42, pp. 115–127, Jan. 2014.
- [183] F. M. Van der Kleij, R. C. W. Feskens, and T. J. H. M. Eggen, "Effects of Feedback in a Computer-Based Learning Environment on Students' Learning Outcomes," *Rev. Educ. Res.*, vol. 85, no. 4, pp. 475–511, Dec. 2015.
- [184] R. W. P. Barry Kort, Rob Reilly, "An Affective Model of Interplay Between Emotions and Learning: Reengineering Educational Pedagogy-Building a Learning Companion," in *Proceedings of the IEEE International Conference on Advanced Learning Technologies*, 2001, p. 43

- [185] B. Woolf, W. Burelson, and I. Arroyo, "Emotional intelligence for computer tutors," in Workshop on modeling and scaffolding affective experiences to impact learning at 13th international conference on artificial intelligence in education, Los Angeles, California, 2007.
- [186] R. W. Picard, "Toward Machines with Emotional Intelligence.," in ICINCO (Invited Speakers), 2004, pp. 29–30.
- [187] H. Lin, F. Pan, Y. Wang, S. Lv, and S. Sun, "Affective Computing in E-learning," in E-learning, InTech, 2010.
- [188] L. Shen, M. Wang, and R. Shen, "Affective e-Learning: Using 'Emotional' Data to Improve Learning in Pervasive Learning Environment," *Journal of Educational Technology & Society*, vol. 12. International Forum of Educational Technology & Society, pp. 176–189, 2009.
- [189] L. P. Tichavsky, A. Hunt, A. Driscoll, and K. Jicha, "'It's Just Nice Having a Real Teacher': Student Perceptions of Online versus Face-to-Face Instruction," *Int. J. Scholarsh. Teach. Learn.*, vol. 9, no. 2, pp. 1–8, Jul. 2015.
- [190] C. J. Auster, "Blended Learning as a Potentially Winning Combination of Face-to-face and Online Learning," *Teach. Sociol.*, vol. 44, no. 1, pp. 39–48, Jan. 2016.
- [191] M. G. Brown, "Blended instructional practice: A review of the empirical literature on instructors' adoption and use of online tools in face-to-face teaching," *Internet High. Educ.*, vol. 31, pp. 1–10, Oct. 2016.
- [192] C. Mühl, B. Allison, A. Nijholt, and G. Chanel, "A survey of affective brain computer interfaces: principles, state-of-the-art, and challenges," *Brain-Computer Interfaces*, vol. 1, no. 2, pp. 66–84, Apr. 2014.
- [193] M. Andujar and J. E. Gilbert, "Let's learn!," in CHI '13 Extended Abstracts on Human Factors in Computing Systems on - CHI EA '13, 2013, p. 703.
- [194] T. O. Zander, C. Kothe, S. Jatzev, and M. Gaertner, "Enhancing Human-Computer Interaction with Input from Active and Passive Brain-Computer Interfaces," Springer, London, 2010, pp. 181–199.
- [195] M. Marchesi and B. Riccò, "BRAVO: a brain virtual operator for education exploiting braincomputer interfaces," in CHI '13 Extended Abstracts on Human Factors in Computing Systems on - CHI EA '13, 2013, p. 3091.
- [196] J. W. Creswell, *Research design: qualitative, quantitative, and mixed methods approaches*. SAGE Publications, 2014.

- [197] I. Seidman, *Interviewing as qualitative research : a guide for researchers in education and the social sciences*. Teachers College Press, 2013.
- [198] Ingrid Daubechies. *Ten Lectures on Wavelets*. Society for Industrial and Applied Mathematics, 1992.
- [199] Wang, Z., & Oates, T., (2015). Imaging time-series to improve classification and imputation. In. *Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence (IJCAI 2015)*, 3939-3945. arXiv:1506.00327
- [200] Minsky, M., & Papert, S. (1969). *Perceptrons*. M.I.T. Press.
- [201] Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408.
- [202] McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133.
- [203] Soon, C. S., Brass, M., Heinze, H.-J., & Haynes, J.-D. (2008). Unconscious determinants of free decisions in the human brain. *Nature Neuroscience*, 11(5), 543–545.
- [204] Wada A, Tsuruta K, Irie R, Kamagata K, Maekawa T, Fujita S, et al. Differentiating Alzheimer's Disease from Dementia with Lewy Bodies Using a Deep Learning Technique Based on Structural Brain Connectivity. *Magnetic Resonance in Medical Sciences* 2019;18:219–24.

POPIS OZNAKA I KRATICA

ANN	Umjetna neuronska mreža (eng. Artificial neural network)
AUC	Područje ispod krivulje (eng. Area under the curve)
BCI	Sučelje mozak-računalo (eng. Brain computer interface)
BLDA	Bayesova linearna diskriminacijska analiza (eng. Bayesian linear discriminant analysis)
CSP	Zajednički prostorni uzorci (eng. Common spatial pattern)
DA	Diskriminantna analiza (eng. Discriminant analysis)
DNN	Duboka neuronska mreža (eng. Deep neural network)
DWT	Diskretna wavelet transformacija (eng. Discrete wavelet transform)
EEG	Elektroencefalografija (eng. Electroencephalography)
EKG	Elektrokardiogram (eng. Electrocardiography)
EPI	Eho planarno snimanje (eng. Echo Planar Imaging)
FIS	Neizrazita (fuzzy) logika (eng. Fuzzy Inference System)
fMRI	Funkcionalna magnetska rezonancija (eng. Functional magnetic resonance imaging)
GADF	Gramiano polje kutne razlike (eng. Gramian Angular Difference Field)
ICA	Neovisna analiza komponenata (eng. Independent component analysis)
KNN	K najbliži susjedi (eng. K-nearest neighbors)
LDA	Linearna diskriminantna analiza (eng. Linear discriminant analysis)
LN	Linearna mreža (eng. Linear network)
MEG	Magnetoencefalografija (eng. Magnetoencephalography)
MLP	Višeslojni perceptron (eng. Multilayer perceptron)
MOOC	Masivni otvoreni internetski tečajevi (eng. Massive Open Online Courses)
MRF	Markovljevo slučajno polje (eng. Markov random field)
MRI	Magnetska rezonancija (eng. Magnetic Resonance Imaging)
MWF	Modifikacija Wenzove formule (eng. Modification of Wenz formula)
NN	Neuronske mreže (eng. Neural network)
P300	Kognitivno evociran potencijal (eng. Cognitive evoked potentials)
PCA	Analiza glavne komponente (eng. Principal component analysis)
RBM	Ograničeni boltzmanov stroj (eng. Restricted Boltzmann machine)
RGB	Crvena, zelena, plava (eng. Red, green, blue)
RGC	Riemanov geometrijski klasifikator (eng. Riemannian Geometry classifier)

RL	Podržno učenje (eng. Reinforcement learning)
RMSE	Korijenska srednja kvadratna pogreška (eng. Root-mean-square error)
RNN	Rekurentna neuronska mreža (eng. Recurrent neural network)
ROC	Krivulja radne karakteristike prijavnika (eng. Receiver Operating Characteristic)
SNR	Omjer signala i šuma (eng. Signal-to-noise ratio)
SPD	Smetrično pozitivno određena matrica (eng. Symmetric positive definite matrix)
SVM	Stroj potpornih vektora (eng. Support-vector machines)
USB	Univerzalna serijska sabirnica (eng. Universal Serial Bus)
WT	Wavelet transformacije (eng. Wavelet transform)