

Detekcija pokreta ruku iz EEG signala primjenom strojnog učenja

Rotim, Sven

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Electrical Engineering and Computing / Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:168:931591>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2025-03-15**



Repository / Repozitorij:

[FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repozitory](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 569

**DETEKCIJA POKRETA RUKU IZ EEG SIGNALA PRIMJENOM
STROJNOG UČENJA**

Sven Rotim

Zagreb, lipanj 2024.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 569

**DETEKCIJA POKRETA RUKU IZ EEG SIGNALA PRIMJENOM
STROJNOG UČENJA**

Sven Rotim

Zagreb, lipanj 2024.

DIPLOMSKI ZADATAK br. 569

Pristupnik: **Sven Rotim (0036522542)**

Studij: Računarstvo

Profil: Računarska znanost

Mentorica: prof. dr. sc. Sonja Grgić

Zadatak: **Detekcija pokreta ruku iz EEG signala primjenom strojnog učenja**

Opis zadatka:

Elektroencefalografija (EEG) je dijagnostički postupak snimanja električne aktivnosti mozga. EEG može pružiti korisne informacije o moždanoj aktivnosti povezanoj s pokretima i motoričkim funkcijama. EEG signali sadrže složene uzorke pa se strojnim učenjem može se ubrzati proces njihove analize, provesti identifikacija složenih veza između komponenata signala te prepoznati specifične oblike signala povezane s različitim pokretima. Cilj diplomskog rada je istražiti mogućnost detekcije pokreta iz EEG signala korištenjem tehnika strojnog učenja. Potrebno je proučiti relevantnu literaturu o detekciji pokreta iz EEG signala te dati pregled postojećih metoda i pristupa. Pripremiti skup podataka koji će obuhvatiti EEG signale povezane s različitim vrstama pokreta. Možete koristiti dostupne baze podataka ili stvoriti vlastiti skup podataka. Provesti pretprocesiranje EEG signala, uključujući filtriranje radi uklanjanja šuma, normalizaciju amplituda, uklanjanje izobličenja i druge korake prema potrebi. Provesti ekstrakciju značajki EEG signala i identificirati one relevantne za razlikovanje obrazaca povezanih s različitim vrstama pokreta. Odabrati model strojnog učenja za klasifikaciju pokreta, provesti implementaciju modela, optimizaciju i evaluaciju. Vrednovati postignute rezultate koristeći odgovarajuće metrike, kao što su točnost, preciznost, odziv i slično. Raspraviti rezultate istraživanja, usporediti ih s relevantnim rezultatima iz literature te razmotriti moguća poboljšanja.

Rok za predaju rada: 28. lipnja 2024.

*Zahvala mentorici prof. dr. sc. Sonji Grgić na odličnom mentorstvu i pomoći pri izradi
diplomskega rada.*

Sadržaj

1. Uvod	3
2. EEG	4
2.1. EEG općenito	4
2.2. Elektrode	5
2.3. EEG signali	7
2.3.1. Delta valovi	7
2.3.2. Theta valovi	8
2.3.3. Alfa valovi	8
2.3.4. Beta valovi	9
2.3.5. Gama valovi	9
2.4. Emotiv EEG uređaj	10
3. Modeli strojnog učenja i mjere performansi	12
3.1. Stroj potpornih vektora	12
3.2. XGBoost	13
3.3. Algoritam slučajnih šuma	14
3.4. Duboki model	15
3.5. Mjere performansi	17
4. Postojeća rješenja za problem prepoznavanja pokreta ruku	19
4.1. Prikupljanje i pretprocesiranje EEG signala	20
4.1.1. Prikupljanje podataka	20
4.1.2. Pretprocesiranje signala	20
4.2. Ekstrakcija i odabir značajki	21
4.3. Modeli strojnog učenja	22

4.4. Rezultati	23
4.4.1. Analiza i usporedba	23
5. Podaci	24
5.1. Sučelje za eksperiment	25
5.2. Prikupljanje podataka	27
5.3. Konačna baza podataka	29
5.4. Obrada podataka	31
5.4.1. Pretprocesiranje	32
5.4.2. Ekstrakcija značajki	33
6. Rezultati i rasprava	34
6.1. Višeklasna klasifikacija	34
6.2. Binarna klasifikacija	38
6.3. Moguća poboljšanja	40
7. Zaključak	41
Literatura	42
Sažetak	44
Abstract	45

1. Uvod

Snimanje električne aktivnosti mozga ima veliki značaj i široku primjenu u raznim područjima, poput medicine i neuroznanosti. Elektroencefalografija (engl. electroencephalography, EEG) omogućava neinvazivno praćenje moždane aktivnosti. Signali dobiveni iz EEG snimanja mogu se koristiti u različite svrhe uključujući detekciju emocija, pokreta i za bolje razumijevanje kognitivnih procesa. Kvalitetna obrada i ekstrakcija značajki iz EEG signala ključni su za preciznu analizu i razumijevanje ovih podataka.

Spoj EEG signala i strojnog učenja sve je češća tema zanimanja različitih znanstvenih radova i istraživača. Korištenjem tehnika strojnog učenja, moguće je istrenirati modele koji prepoznaju određene obrasce aktivnosti mozga i povezuju ih s motoričkim funkcijama.

Ovaj rad istražuje različite metode strojnog učenja za detekciju pokreta ruku iz EEG signala. Istražuju se različite tehnike procesiranja signala i ekstrakcije značajke te primjena različitih algoritama strojnog učenja kako bi se dobili što bolji rezultati.

2. EEG

2.1. EEG općenito

EEG je dijagnostički postupak snimanja električne aktivnosti mozga. EEG se smatra neinvazivnom metodom za procjenu neurofizioloških stanja, postupak mjeri električnu aktivnost velikih sinkrono aktiviranih populacija neurona u mozgu pomoću elektroda postavljenih na vlasište subjekta [1]. Signali dobiveni snimanjem EEG-a izraženi su u voltima (mikrovoltima).

EEG se koristi za identificiranje različitih neuroloških poremećaja poput epilepsije, Alzheimerove bolesti itd. Isto tako koristi se za istraživanje mozga i kognitivnih funkcija. Međutim, u novije vrijeme sa sve većom prisutnošću i razvojem strojnog učenja, prepoznavanje emocija ili pokreta pomoću EEG signala i različitih tehnika strojnog učenja je sve popularnije.

EEG je iznimno učinkovit u praćenju promjena električne aktivnosti mozga u stvarnom vremenu. Međutim, kod određivanja točnih mjesta tih promjena, EEG ima ograničenja i ne može precizno locirati te promjene. Zato kažemo da EEG ima visoku vremensku, ali nisku prostornu složenost [1].

Možemo razlikovati dvije vrste EEG uređaja: prijenosne i ne-prijenosne. Prijenosni uređaji su bežični i namijenjeni za uporabu izvan laboratorijskog okruženja. Njihova primarna prednost je što su mobilni i lagani za koristiti. Međutim, baš zbog tih pogodnosti dobiveni signali mogu biti lošije kvalitete zbog pokreta i buke iz okoline te uglavnom manjeg broja elektroda.

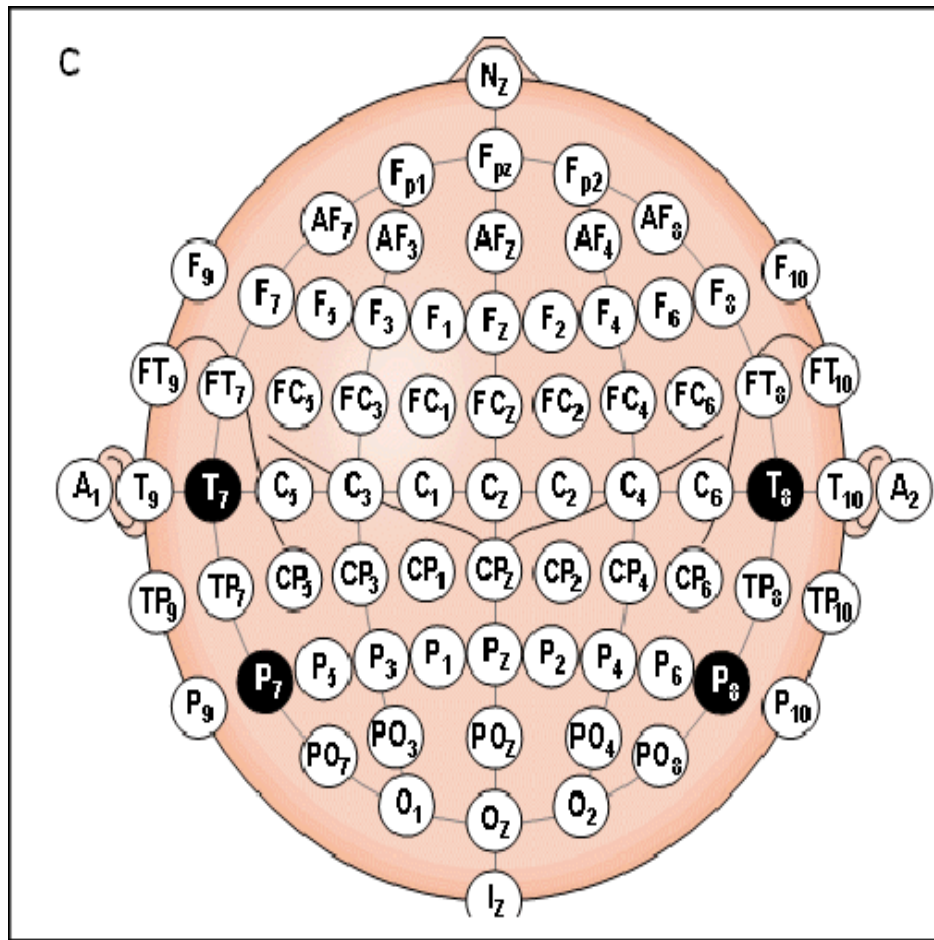
Ne-prijenosni uređaji se najčešće koriste u istraživačkom odnosno laboratorijskom okruženju i pružaju podatke veće kvalitete.

2.2. Elektrode

Snimanje se provodi postavljanjem elektroda na vlasište ispitanika te se mjere signali koje proizvode neuroni u mozgu. Elektrode registriraju i prenose dobivene signale na EEG uređaj. Raspored elektroda radi se po internacionalnom 10-20 sustavu prikazanom na slici 2.1. Naziv 10-20 se odnosi na stvarnu udaljenost između susjednih elektroda, ta udaljenost je 10% ili 20% ukupne udaljenosti od prednje do stražnje strane ili s lijeve na desnu stranu lubanje, drugim riječima udaljenost je proporcionalna veličini i obliku lubanje ispitanika. Nazivlje elektroda je određeno njihovim položajem na vlasištu. Ime počinje slovom koje određuje regiju mozga te brojem (ili slovom Z) koji određuje stranu. Neparni brojevi označavaju položaj na lijevoj strani lubanje, parni na desnoj, a slovo Z na sredini. Regije mozga su predstavljene sljedećim slovima:

- F - frontalna,
- T - temporalna,
- P - parijetalna,
- O - okcipitalna,
- C - središnja.

Središnje područje iako nije anatomske rezanj poput ostale četiri bitno je zbog informacija o motoričkoj kontroli koju dobivamo iz tog dijela mozga.



Slika 2.1. Položaj elektroda [2]

Uz navedene glavne regije mozga i pripadne im nazive elektroda, postoje još tri bitne skupine: Fp, AF i FC. Fp pokriva prefrontalno područje. AF pokriva dio vlasišta između elektroda s nazivljem Fp i F, a FC pokriva dio vlasišta između elektroda s nazivljem F i C.


Broj elektroda koji se koristi u EEG snimanjima ima veliku ulogu u preciznosti i kvaliteti dobivenih signala. Većim brojem elektroda može se pokriti veći dio vlasišta te se tako dobivaju detaljniji i bolji rezultati. Broj elektroda je u pravilu veći kod neprijenosnih EEG uređaja.

2.3. EEG signali

EEG omogućuje analizu različitih moždanih valova koji se generiraju unutar mozga. Ovi moždani valovi odražavaju električnu aktivnost mozga i pružaju vrijedne informacije o različitim stanjima svijesti, funkcijama mozga i neurološkim poremećajima. Postoji pet osnovnih vrsta takvih valova koji se razlikuju po frekvencijama i funkcijama kod kojih su prisutni. To su alfa, beta, gama, theta i delta valovi. U ovom poglavlju, istražiti ćemo te različite vrste valova koji se dobivaju te kasnije analiziraju u EEG snimkama.

2.3.1. Delta valovi


Delta valovi imaju najnižu frekvenciju, manju od 4 Hz, slika 2.2. Prisutni su kod dubokog sna te se povezuju s fizičkim oporavkom. Normalna proizvodnja delta valova nam omogućuje da se osjećamo dobro i odmorno nakon buđenja. Povećana aktivnost ovih valova kod pokušaja koncentracije smanjuje sposobnost koncentracije i pažnje što je često prisutno kod osoba s poremećajem pažnje [3, 4].



Slika 2.2. Delta valovi [5]

2.3.2. Theta valovi


Theta valovi imaju frekvenciju između 4 i 8 Hz, slika 2.3. Prisutni su kod sna, sanjarenja, ali i kod meditacije. Povezuju se s kreativnošću te doživljajem emocija. Javljaju su i pri obavljanju automatskih zadataka pri kojima ne trebamo puno razmišljati poput vožnje [3, 4].



Slika 2.3. Theta valovi [5]

2.3.3. Alfa valovi


Alfa valovi imaju frekvenciju između 8 i 12 Hz, slika 2.4. Prisutni su kada je osoba budna i u stanju duboke opuštenosti. Velika aktivnost ovih valova može ukazivati na stanje smirenosti i smanjenoga stresa odnosno kada se osjećamo ugodno i opušteno. Regija mozga u kojima su ovi valovi najprisutniji je okcipitalna regija [3, 4].



Slika 2.4. Alfa valovi [5]

2.3.4. Beta valovi


Beta valovi imaju frekvenciju između 12 i 30 Hz, slika 2.5. Prisutni su kod budnog stanja i mentalne aktivnosti. Bitni su kod izvršavanja različitih zadataka (školskih, vezanih za posao itd.). Zbog svojeg velikog raspona razlikuju se beta valovi s nižim te višim frekvencijama. Povećani beta valovi ukazuju na anksioznost i povećani stres. Niži beta valovi se vežu uz rješavanje zadataka i mentalnu fokusiranost. Regije u kojima su ovi valovi najizraženiji su parijetalna i frontalna regija [3, 4].



Slika 2.5. Beta valovi [5]

2.3.5. Gama valovi

Gama valovi imaju frekvenciju iznad 30 Hz, slika 2.6. Povezani su s višim kognitivnim funkcijama te su važni za učenje, pamćenje i obradu informacija. Nalaze se u svim regijama mozga [3, 4].



Slika 2.6. Gama valovi [5]

2.4. Emotiv EEG uređaj

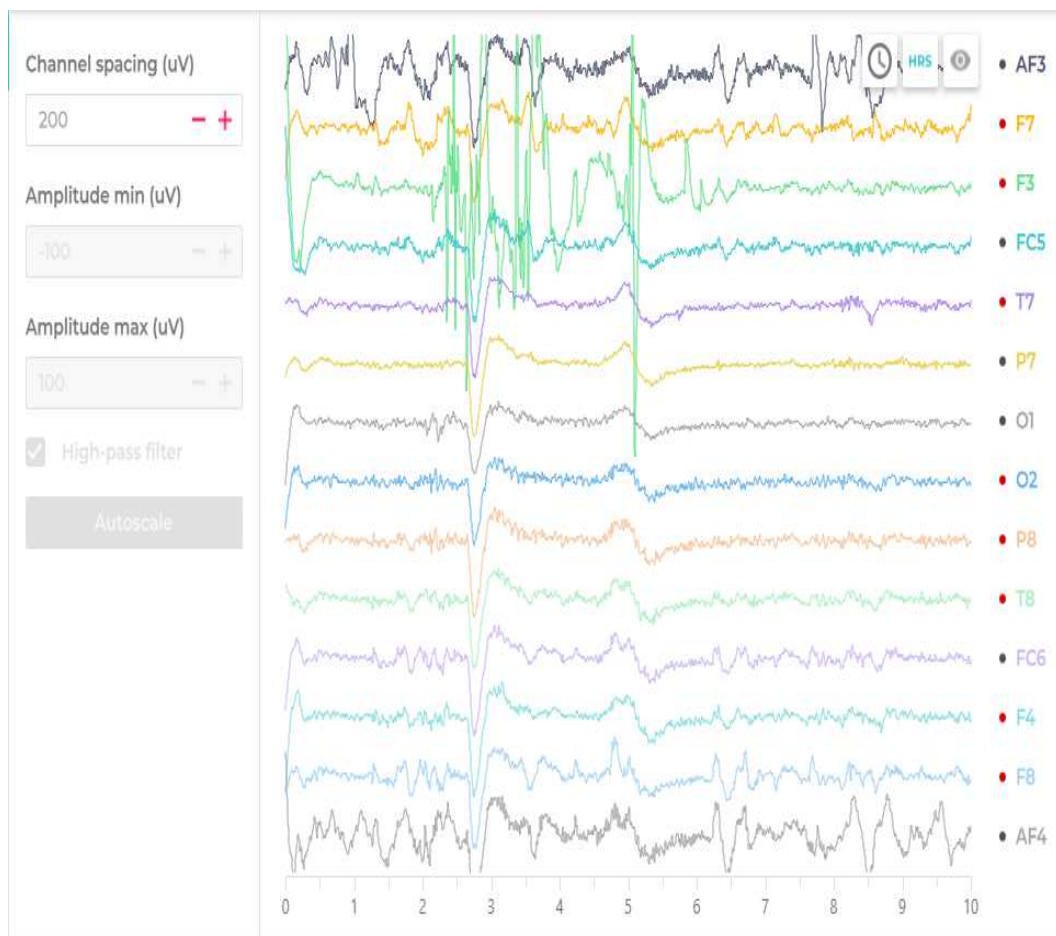
Emotiv Epoc X prijenosni je EEG uređaj s 14 elektroda (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) raspoređenih po internacionalnom 10-20 sustavu. Uređaj uz detektiranje EEG signala također prati promjene položaja glave. Bluetooth tehnologija mu daje jednostavnost korištenja te brzi i pouzdan prijenos signala u stvarnom vremenu. Iako je bežičan, podaci dobiveni pomoću Epoc X uređaja su kvalitetni i mogu se koristiti u istraživačke svrhe. Uređaj je udoban za korištenje što ga čini idealnim za dugotrajna istraživanja. Na slici 2.7. prikazan je Emotiv Epoc X uređaj.

EmotivPRO software u kombinaciji s Emotiv Epoc X uređajem omogućuje snimanje EEG signala u stvarnom vremenu, njihovu vizualizaciju te izvoz tih signala u različitim oblicima (CSV, .mat format). Slika 2.8. prikazuje EmotivPro software tijekom snimanja EEG signala, na slici se vidi vizualizacija signala u stvarnome vremenu zasebno po svim elektrodama.

Zbog svih navedenih karakteristika ovaj uređaj ima široku primjenu, od izrade znanstvenih radova do različitih istraživanja povezanih s mjerenjem aktivnosti mozga [6].



Slika 2.7. Emotiv Epoc X [6]

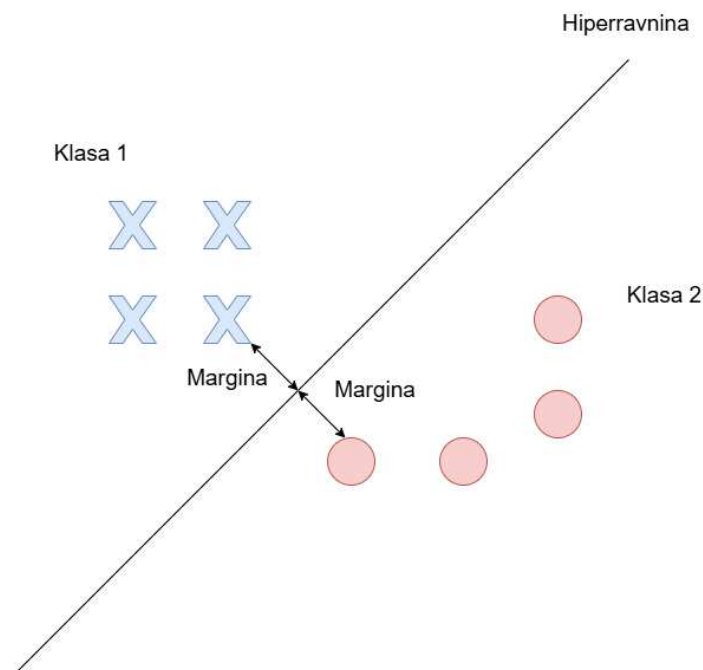


Slika 2.8. EmotivPro software

3. Modeli strojnog učenja i mjere performansi

3.1. Stroj potpornih vektora

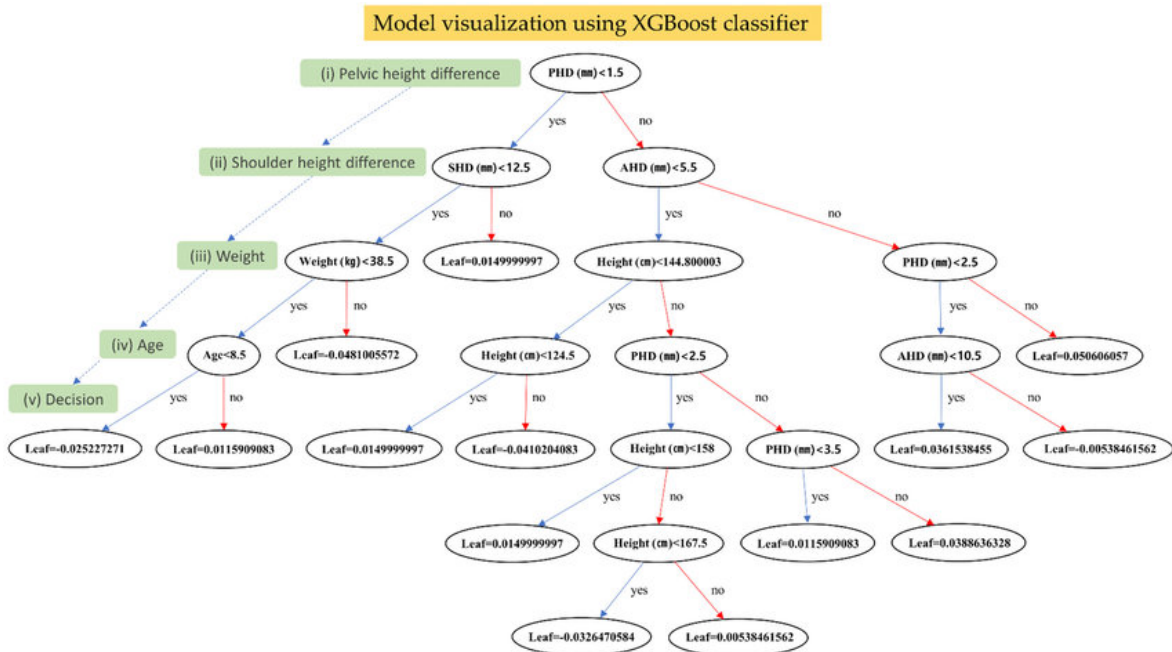
Stroj potpornih vektora (engl. support vector machine, SVM) je učinkoviti algoritam za klasifikaciju i regresiju i posebno je učinkovit u prostorima velikih dimenzija, slika 3.1. Ovaj algoritam temelji se na ideji maksimalne margine. Margina je udaljenost hiperravnine koja odvaja primjere različitih klasa do najbližeg primjera svake klase. Takvih hiperravnina može bit beskonačno mnogo, a SVM uzima onu koja maksimizira marginu [7].



Slika 3.1. SVM

3.2. XGBoost


Algoritam strojnog učenja ekstremno pojačavanje gradijenta (engl. eXtreme Gradient Boosting, XGBoost) radi na način izgradnje stabala odlučivanja, slika 3.2. Svako novo stablo pokušava ispraviti pogreške prethodnih stabala i tako se model iterativno usavršava. Naziv dolazi iz toga što ovaj algoritam implementira povećanje gradijenta. Njegove prednosti su mogućnost obrade velikih skupova podataka, regularizacija, automatsko rukovanje s podacima koji nedostaju i paralelno izvođenje [8].



Slika 3.2. XGBoost [9]

3.3. Algoritam slučajnih šuma

Algoritam slučajnih šuma je algoritam strojnog učenja koji kombinira više stabala odlučivanja, slika 3.3. Svako stablo odlučivanja ovisi o vrijednostima slučajnog vektora neovisno uzorkovanog s istom distribucijom za sva stabla u šumi. Svako stablo u šumi daje svoje predviđanje klase te se za konačnu klasifikaciju uzima klasa s najviše glasova [10].



Slika 3.3. Slučajne šume [11]

3.4. Duboki model

Duboki modeli odnosno modeli dubokog učenja podskup su algoritama strojnog učenja. Ovi modeli se nazivaju dubokima zato što sadrže više slojeva u svojoj mreži. Posebno su korisni za zadatke koji uključuju visokodimenzionalne podatke i složene obrasce. Neke od čestih primjena dubokih modela su: prepoznavanje slika i obrada prirodnog jezika.

Za ovaj rad napravljen je duboki model za prepoznavanje pokreta ruku iz EEG signala. Arhitektura tog modela sastoji se od konvolucijskog sloja, aktivacijske funkcije zglobnice, max-pooling sloja, potpuno povezanog sloja te aktivacijske funkcije sigmoida. Duboki model može se opisati kroz sljedeće korake.

1. Prvi sloj je konvolucijski sloj. Sadrži 14 ulaznih kanala te 64 izlaznih kanala, veličina jezgre je tri.
2. Nakon konvolucijskog sloja slijedi aktivacijska funkcija zglobnice.
3. Drugi sloj je max-pool sloj s veličinom jezgre dva i pomakom dva. Ovaj sloj umanjuje dimenzija ulaza na polovicu originalne veličine.
4. Treći sloj je potpuno povezani sloj. Prije nego podaci ulaze u taj sloj, moraju su prebaciti iz dvije dimenzije (2d podaci) u jednu dimenziju (1d podaci) za svaki podatak iz grupe. U ovome sloju imamo 3776 ulaza i 128 izlaza.
5. Nakon potpuno povezanog sloja koristi se aktivacijska funkcija zglobnice.
6. Zadnji sloj je također potpuno povezani sa 128 ulaza i dva izlaza.
7. Na kraju se provodi aktivacijska funkcija sigmoida na oba izlaza iz zadnjega sloja.

Na slici 3.4. prikazan je kod dubokog modela. Model prima tri argumenta kod inicijalizacije. Veličina značajki ulaza (shape) definira duljinu ulaznih podataka koje će model obrađivati. Broj ulaznih kanala (in_channels) je definiran brojem elektroda. Broj izlaznih kanala (out_channels) označava veličinu izlaza modela, taj parametar definiran je brojem klasa.

```
class DubokiModel(nn.Module):
    def __init__(self, shape, in_channels=IN_CHANNELS, out_channels=OUT_CHANNELS):
        super(NNet, self).__init__()

        self.conv1 = nn.Conv1d(in_channels=in_channels, out_channels=64, kernel_size=3)
        self.pool = nn.MaxPool1d(kernel_size=2, stride=2)
        self.fc1 = nn.Linear(64 * ((shape - 2) // 2), 128)
        self.fc2 = nn.Linear(128, out_channels)

        self.relu = nn.ReLU()
        self.logistic = nn.Sigmoid()

    def forward(self, x):
        x = self.conv1(x)
        x = self.relu(x)
        x = self.pool(x)

        x = x.view(x.size(0), -1)
        x = self.fc1(x)
        x = self.relu(x)
        x = self.fc2(x)
        x = self.logistic(x)

    return x
```

Slika 3.4. Duboki model

3.5. Mjere performansi

Mjere koje se najčešće koriste kako bi se utvrdili rezultati rada su: točnost, preciznost, odziv te F1-mjera.

Matrica zabune

Matrica zabune sadrži četiri kategorije u sebi i iz nje se mogu očitati sve navedene mjere, tablica 3.1.

- TP - true positive,
- FP - false positive,
- FN - false negative,
- TN - true negative.

Tablica 3.1. Matrica zabune

	Predviđena pozitivna klasa	Predviđena negativna klasa
Pozitivna klasa	TP	FN
Negativna klasa	FP	TN

Točnost

Točnost mjeri omjer točno klasificiranih uzoraka u odnosu na ukupan broj uzoraka.

$$\text{Točnost} = \frac{TP + TN}{TP + TN + FP + FN}$$

Preciznost

Preciznost je omjer točno klasificiranih uzoraka u skupu pozitivno klasificiranih uzoraka.

$$\text{Preciznost} = \frac{TP}{TP + FP}$$

Odziv

Odziv je omjer točno klasificiranih uzoraka u skupu svih pozitivnih uzoraka.

$$\text{Odziv} = \frac{TP}{TP + FN}$$

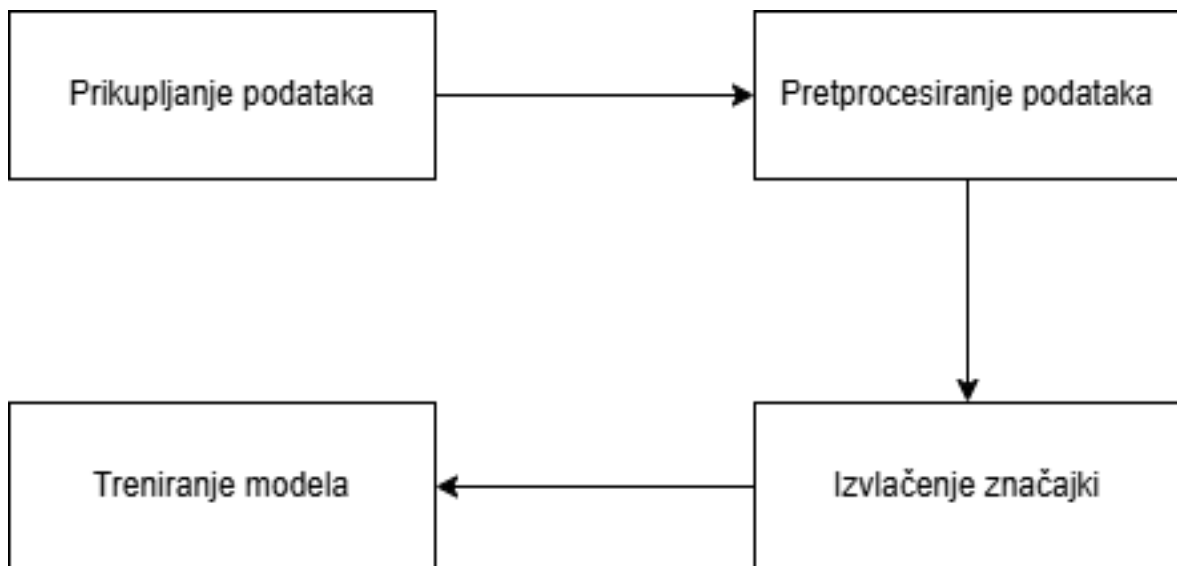
F1-mjera

F1-mjera je harmonijska sredina preciznosti i odziva.

$$\text{F1-mjera} = 2 \times \frac{\text{Preciznost} \times \text{Odziv}}{\text{Preciznost} + \text{Odziv}}$$

4. Postojeća rješenja za problem prepoznavanja pokreta ruku

Uz rastuću popularnost spajanja EEG-a i strojnog učenja nastala je značajna količina znanstvenih radova na tu temu. Ovo poglavlje predstavlja kratki pregled nekih od značajnijih radova u ovome području te usporedbu metodologije i tehnika različitih istraživača. Iako postoje sličnosti u pristupima ovih radova, također postoji i velika raznolikost te prostor za inovacije u ovome području. Slika 4.1. prikazuje osnovne korake izrade radova za problem prepoznavanja pokreta ruku pomoću EEG signala koristeći strojno učenje.



Slika 4.1. Koraci izrade rada

4.1. Prikupljanje i pretprocesiranje EEG signala

Prikupljanje te procesiranje EEG signala ključan je korak za točno detektiranje pokreta ruku. Kvaliteta dobivenih signala te način na koji su dobiveni uvelike utječe na rezultat i predstavlja veliki izazov. EEG signali sadrže dosta šuma pa ih je potrebno dobro obraditi kako bi se poboljšala njihova kvaliteta.

4.1.1. Prikupljanje podataka

Postoje javno dostupne baze podataka EEG signala koje se koriste u brojnim znanstvenim radovima. Prednost korištenja ovih standardiziranih skupova podataka je u lakšoj i preciznijoj usporedbi rezultata sa srodnim radovima, pošto se eliminira razlika u prikupljanju podataka te sama varijabilnost u njihovoj kvaliteti. S druge strane veliki broj radova ne koristi spomenute skupove podataka nego prikupljaju svoje signale odnosno podatke. Prednost ovog pristupa je postavljanje eksperimenta te dobivanje signala točno prilagođenih zadanom problemu. U svim skupovima podataka, bili oni javno dostupni ili posebno napravljeni za određeni rad, rade se mjerenja dok sudionici miruju te tijekom obavljanja nekih radnji. Razlike među radovima se nalaze u drugom navedenom koraku, mjerenju signala tijekom obavljanja određenih radnji i tu ima različitih pristupa.

Javno dostupni skupovi podataka EEG signala često uključuju mjerenja tijekom pokreta lijeve i desne ruke sudionika, što ih čini dobrim izvorom za treniranje te testiranje različitih modela strojnog učenja. Ovi podaci su korišteni u brojnim radovima za analizu performansi i klasifikaciju EEG signala [12, 13, 14]. S druge strane, neki radovi koriste posebno izrađene skupove podataka prilagođene specifičnim eksperimentalnim uvjetima, što omogućuje precizniju prilagodbu signala zadanom istraživačkom problemu [15].

4.1.2. Pretprocesiranje signala

Pretprocesiranje EEG signala iako je jako bitan dio svih radova na ovu temu, nema velikih razlika u postupcima pretprocesiranja među različitim radovima. Glavni koraci pretprocesiranja su filtriranje signala i uklanjanje nepoželjnih artefakata. Filtriranje signala uključuje korištenje visoko-propusnih, nisko-propusnih te pojasno-propusnih filtara za uklanjanje šuma. Također, veliku važnost ima i "Notch filter" [13, 14]. Taj filter propušta

sve frekvencije osim jako uskog pojasa oko određene ciljane frekvencije. Njegova važnost je kod uklanjanja elektromagnetskih smetnji koje nastaju od električnih mreža na frekvenciji poput 50 Hz u Europi ili 60 Hz u SAD-u. Uklanjanje nepoželjnih artefakata izazvanih pomicanjem očiju, treptanjem ili drugim pokretima obavlja se pomoću analize nezavisnih komponenti (engl. independent component analysis, ICA) [13]. Dodatan korak koji je čest u procesu pretprocesiranja signala je normalizacija, ovaj postupak prvo računa srednju vrijednost svih signala u skupu te se potom ta srednja vrijednost oduzima od svakog signala [13, 14].

4.2. Ekstrakcija i odabir značajki

Nakon što su podaci prikupljeni i obrađeni sljedeći korak je provesti ekstrakciju i odabir značajki koje će se koristiti za treniranje modela strojnog učenja. Rezultat ovog koraka uvelike utječe na model i na njegovu sposobnost raspoznavanja različitih uzoraka odnosno klasa.

Postoji nekoliko različitih tehnika koje se koriste za ekstrakciju značajki iz EEG signala, najvažnije su značajke vremenske domene i značajke frekvencijske domene.

Značajke vremenske domene uključuju mjere kao što su srednja vrijednost, varijanca i standardna devijacija signala.

Značajke frekvencijske domene dobivaju se korištenjem tehnika poput brzih Fourierovih transformacija (engl. Fast Fourier Transform, FFT). FFT je algoritam koji signalima iz vremenske domene dodjeljuje reprezentaciju u frekvencijskoj domeni. Također, jedna od tehnika je spektralna gustoća snage (engl. Power Spectral Density, PSD). PSD je mjera koja prikazuje raspodjelu snage signala po frekvencijama, opisuje se koliko energije signal ima na različitim frekvencijama.

Ove mjere računaju se zasebno za svaku elektrodu te postoje brojne kombinacije dobivanja ovih značajki, kao dodatan faktor nameće se odabir vremenskog prozora (intervala) na temelju kojega će značajke biti izračunate. Broj dobivenih značajki može jako varirati što može utjecati kod daljnjeg odabira i performansi modela strojnog učenja [12, 13, 14, 15].

4.3. Modeli strojnog učenja

Detekcija pokreta ruku je klasifikacijski problem strojnog učenja, izbor algoritama koji su pogodni za to je velik, no ima puno faktora koji utječu na to kao i na same rezultate. Sama vrsta problema koji se obrađuje može biti raznolika, od jednostavne klasifikacije koja samo pokušava odrediti koja ruka je napravila pokret (lijeva ili desna), do složenijih koje pokušavaju prepoznati više vrsta pokreta. Isto tako i broj ulaznih značajki u model je jedan od faktora koji se mora uzeti u obzir pri odabiru algoritma.

Dio istraživačkih radova se odlučilo isprobati više različitih algoritama i tehnika, takvim pristupom dobiveni rezultati su relevantni u smislu da su korišteni isti signali odnosno značajke dobivene iz njih za treniranje i testiranje modela [12]. Sličan pristup, ali izveden na drugačiji način je isprobavanje više modela, ali ne različitih, nego istih samo s drugačijim podskupom odabranih značajki za ulaz u model [13].

Modeli koji se često koriste u radovima uključuju SVM i neuronske mreže [13], duboke modele poput ćelija s dugoročnom memorijom (engl. Long short-term memory, LSTM) [14], te kombinacije jednostavnijih modela (algoritam slučajnih šuma, logistička regresija, algoritam k najbližih susjeda) i dubokog učenja [12].

4.4. Rezultati

Rezultati navedenih istraživanja, a i svih ostalih na ovu temu pokazuju kako različito prikupljanje podataka, odabir tehnika pretprocesiranja, izdvajanja značajki i modela uvelike utječu na rezultat točnosti modela kod klasifikacije pokreta ruku na temelju EEG signala.

Najveća postignuta točnost u istraživanjima pokazuje značajne varijacije ovisno o korištenim metodama. Na primjer, korištenje SVM-a rezultiralo je najvećom točnošću od 97% na binarnoj klasifikaciji [13]. Upotreba LSTM modela rezultirala je točnošću od 93% na višeklasnoj klasifikaciji (tri klase) [14], dok je korištenje XGBoost modela rezultiralo točnošću od 88% na binarnoj klasifikaciji [12].

4.4.1. Analiza i usporedba

Svi navedeni radovi daju veliku važnost učinkovitoj obradi podataka, ekstrakciji i odabiru značajki i odabiru modela prilagođenoga pojedinom zadatku. Ako samo jedna od ovih stavki nije dobro napravljena mogući su loši krajnji rezultati, zato je jako bitno sve korake napraviti temeljito kako bi se postigla što bolja točnost klasifikacije.

5. Podaci

Kako bi se uspješno napravio model koji detektira pokrete ruku iz EEG signala, prvo je potrebno prikupiti podatke koji precizno reflektiraju moždanu aktivnost povezanu s tim pokretima. U ovom istraživanju prikupljeni su podaci o tri različita stanja: stanje mirovanja, pokret desne ruke i pokret lijeve ruke.

Snimanje EEG signala obavljeno je pomoću Emotiv Epoc X prijenosnog uređaja uz pomoć Python sučelja koji u stvarnom vremenu označuje i sprema dobivene podatke.

Nakon prikupljanja, EEG signali su obrađeni kako bi se uklonio šum koji bi mogao negativno utjecati na rezultat modela. Obrađeni podaci su potom korišteni za treniranje i testiranje modela strojnog učenja. Model je treniran da razlikuje EEG obrasce povezane s mirovanjem, pokretima desne ruke i pokretima lijeve ruke.


5.1. Sučelje za eksperiment

Pažljivo je osmišljen eksperiment pomoću kojega će se dobiti kvalitetni podaci za daljnju obradu. Eksperiment se sastoji od niza instrukcija koji se prikazuju subjektu na ekranu te ih on izvršava. Za provedbu ovakvog eksperimenta napravljeno je jednostavno sučelje u Pythonu za prikaz instrukcija. Instrukcije su vremenski označene, svaka instrukcija ima zadano vrijeme (u sekundama), koje označava koliko dugo traje odnosno koliko dugo je potrebno izvršavati tu radnju. Također uz prikazano vrijeme, prikazuje se i ime instrukcije. Ime "RIGHT" predstavlja pokret desne ruke dok ime "LEFT" predstavlja pokret lijeve ruke. Prije i nakon svake instrukcije subjekt miruje te mu je na ekranu prikazana sljedeća instrukcija koju će izvoditi te vremensko odbrojavanje do sljedeće instrukcije. Redoslijed prikazivanja, a samim time i izvođenja instrukcija je potpuno slučajan.

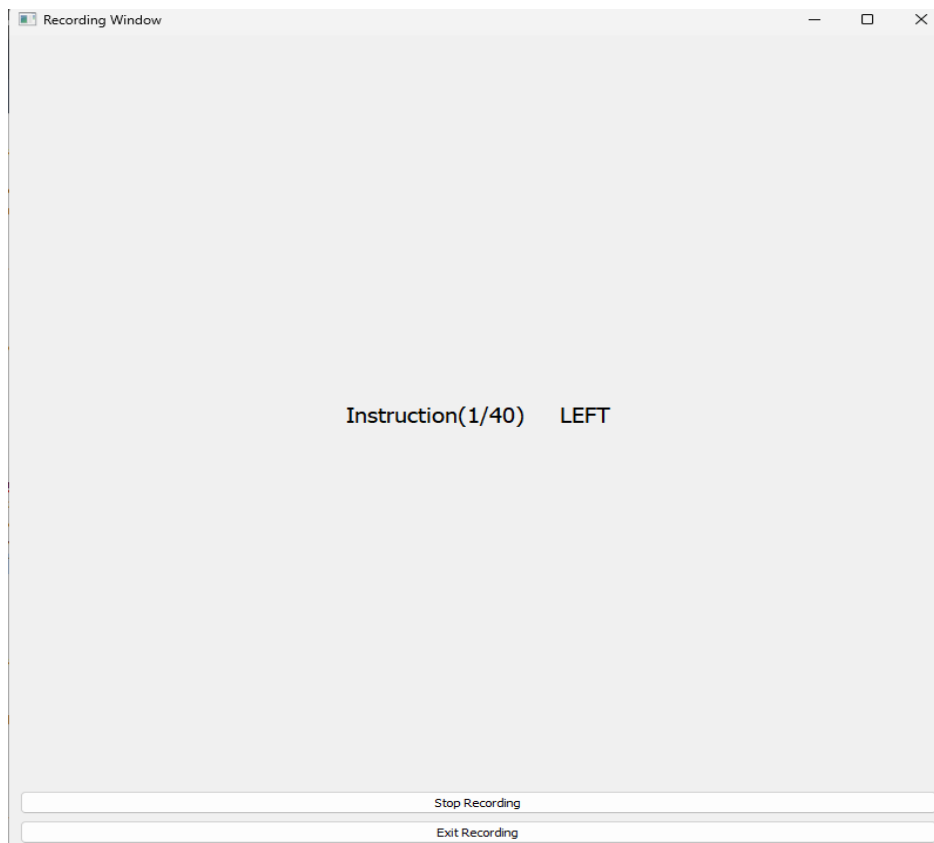
Zadane instrukcije su predodređene u programskome kodu, ali se na jednostavan način mogu modificirati (dodati nove instrukcije, promijeniti trajanje ili ime postojećih instrukcija). Također, trajanje cijeloga eksperimenta se može promijeniti povećanjem ili smanjivanjem broja instrukcija ili samo promjenom vremena jedne ili više od instrukcija. Instrukcije su međusobne nezavisne te po potrebi mogu imati različito trajanje.

Opisano sučelje je namjerno jednostavnog izgleda kako bi se subjekt mogao što bolje fokusirati na samo izvođenje instrukcija bez ikakvih dodatnih smetnji. Time se pokušava što više smanjiti šum u dobivenim podacima što olakšava njihovu daljnju obradu i potencijalno dobivanje boljih rezultata na klasifikaciji modela strojnog učenja.

Slike 5.1. i 5.2. prikazuju osnovni način rada opisanoga sučelja. Slika 5.1. pokazuje ekran u trenutku kada je subjekt u stanju mirovanja i na ekranu mu je prikazana sljedeća instrukcija koju treba napraviti te odbrojavanje do samoga izvođenja. Slika 5.2. pokazuje ekran u trenutku kada subjekt izvodi prikazanu instrukciju.



Slika 5.1. Odmor između instrukcija



Slika 5.2. Instrukcija

5.2. Prikupljanje podataka

U prikupljanju podatak sudjelovao je jedan subjekt (muško, 23 godine). Eksperiment se proveo u dva različita dana. Sveukupno je napravljeno 18 EEG snimanja.

Subjekt i postavke eksperimenta

U ovome eksperimentu sudjelovao je zdrav 23-godišnji muškarac. Eksperimenti su izvođeni u kontroliranom okruženju kako bi se smanjila mogućnost za bilo kakvim vanjskim smetnjama koje bi mogle utjecati na EEG snimanja te izazvati šum u podacima. Subjekt je sjedio u mirnoj sobi, na glavu mu je postavljen Emotiv Epoc X prijenosni EEG uređaj s 14 elektrodi razmještenih po 10-20 internacionalnom sustavu kako bi mu se snimala aktivnost mozga tijekom izvođenja različitih pokreta ruku.

Prvi dan snimanja

Na prvom danu provođenja eksperimenta cilj je bio snimiti EEG signale dok subjekt izvode sljedeće tri radnje: mirovanje, podizanje desne ruke i podizanje lijeve ruke. Postupak na koji su se provodila ova snimanja osmišljen je s namjerom dobivanja dovoljno velikog i preciznog skupa podataka na temelju kojega će kasnije model strojnog učenja moći kvalitetno klasificirati između ovih stanja.

Postupak prvog dana snimanja

Prije i poslije svakog podizanja ruke subjekt je bio u stanju mirovanja (ruke položene na stol). Trajanje svakoga razdoblja odmora trajalo je između dvije i pet sekundi (svaki put je nasumično određeno trajanje). Podizanje lijeve i desne ruke izvodilo se na isti način. Kada bi na ekranu vidio instrukciju subjekt bi izveo prikazanu radnju te se potom vratio u stanje mirovanja. Trajanje podizanja ruku trajalo je svaki puta jednako: tri sekunde. U ovome danu dobiveno je ukupno 10 snimki. Svaka snimka sastojala se od 20 podizanja desne ruke, 20 podizanja lijeve ruke te 40 odmora između tih akcija, sveukupno 80 akcija odnosno instrukcija. Ponavljanje eksperimenta 10 puta u istim uvjetima pruža nam konzistentnost u podacima te učinkovitost za treniranje modela strojnog učenja.

Drugi dan snimanja

U drugome danu snimanja proveden je eksperiment sličan kao i u prvome danu. Razlika je u pokretu ruku koji se izvodio. Subjekt je izvodio sljedeće tri radnje: mirovanje, stiskanje desne šake, stiskanje lijeve šake. Cilj ovoga bio je proširiti opseg snimljenih pokreta kako bi krajnji skup podataka imao veću raznolikost pokreta te kako bi potom model na temelju toga mogao dobiti bolje rezultate.

Postupak drugoga dana snimanja

Kao i prvoga dana, subjekt je prije i poslije svakog stiska šake bio u stanju mirovanja. Stanje mirovanja je također trajalo nasumično između dvije i pet sekundi. Stisak lijeve i desne šake izvodio se na isti način. Na prikazanu instrukciju na ekranu subjekt je izveo prikazanu radnju te potom opustio šaku tj. vratio se u stanje mirovanja. Trajanje stiska šake trajalo je kao i odmor nasumično između dvije i pet sekundi. Ovakvim postupkom pokušano je uvesti varijabilnost u dobivene podatke te kako bi se dobili različiti rasponi stiska šake. Drugoga dana dobiveno je ukupno osam snimki po opisanome postupku. Svaka snimka sadrži 20 stiskanja lijeve šake, 20 stiskanja desne šake te 40 odmora između tih akcija.

5.3. Konačna baza podataka

Nakon što su završena sva EEG snimanja, sve prikupljene snimke su spojene u jedan veliki skup podataka. Ovaj skup podataka je dovoljno velik i raznolik za efikasno treniranje i testiranje modela, s ciljem postizanja dobre generalizacije modela strojnog učenja na ovim podacima.

Ukupno je prikupljeno 1,010,312 podataka. Od tog broja, 896,918 podataka je odvojeno za treniranje modela, dok je preostalih 113,394 podataka korišteno za testiranje. Da bi se osiguralo da model nije prenaučan za specifičnu vrstu pokreta, poput dizanja ruke ili stiska šake, za testiranje je pažljivo odabran jednak broj podataka za svaku vrstu pokreta.

Svaki zapis u skupu podataka predstavljen je kao jedan redak koji sadrži oznaku vremena, vrijednosti signala za svaku od 14 elektroda te oznaku klase na kraju. Klase su definirane na sljedeći način: klasa 0 označava stanje mirovanja, klasa 1 pokret desne ruke, a klasa 2 pokret lijeve ruke. Vrijednosti signala izražene su u mikrovoltima (μV).

Slika 5.3. prikazuje prvih nekoliko redaka snimke dobivene prvoga dana snimanja, dok slika 5.4. prikazuje prvih nekoliko redaka snimke dobivene drugoga dana.

5.4. Obrada podataka

Nakon što su podaci prikupljeni potrebno ih je pretprocesirati i zatim izvući značajke iz njih na temelju kojih će se učiti model. Podaci iz 16 snimki su zatim spojeni kako bi se na njima trenirao model, a 2 snimke su spojene za kasnije testiranje modela. Podjela skupa za treniranje i testiranje po posebnim snimkama napravljeno je iz razloga kako bi se bolje simulirali neviđeni podaci modelu kod testiranja i provjerila modelova sposobnost generalizacije. Kako bi dobili što bolje informacije iz podataka podijelili smo ih u tri klase:

- podaci za vrijeme mirovanja,
- podaci tijekom pokreta desne ruke (dizanje ruke i stisak šake),
- podaci tijekom pokreta lijeve ruke (dizanje ruke i stisak šake).

Podaci su na ovaj način podijeljeni i u skupu za treniranje i u skupu za testiranje. Podjela se radila tako da su uzeti samo segmenti duljine 256 signala (ako je stanje mirovanja ili pokreta trajalo duže uzeto je samo prvih 256 signala te akcije). To je napravljeno kako bi za daljnju obradu imali ujednačene podatke te samim time uspjeli dobiti bolje informacije iz njih na kojima će se kasnije trenirati model. Zatim se smanjio broj podataka klase mirovanja, kojih je bilo više nego ostale dvije klase. Ovaj korak je bitan da bi se dobila uravnoteženost između broja podataka svih klasa.

5.4.1. Pretprocesiranje

Kod pretprocesiranja podataka cilj je bio ukloniti šum iz neobrađenih podataka odnosno dobiti što čišće podatke za daljnje korake. Za filtriranje podataka koristilo se pojasno filtriranje. EEG signali sadrže razne frekvencije, ali nisu sve od njih relevantne za analizu pokreta ruku. Korištenjem pojasnog filtriranja ostavljamo samo frekvencije koje su nam bitne za daljnju analizu dok neželjene frekvencije izbacujemo. Određena je donja i gornja granica za filter. Sve frekvencije između tih granica će biti propuštene, a sve izvan će se odbaciti. Pošto su nam od posebnog zanimanja frekvencijski pojasevi moždanih valova, posebno se za svaki od tih pojasa radilo filtriranje te zatim daljnja ekstrakcija značajki. To je napravljeno kako bi dobili odvojene značajke za svaki od željenih pojasa. U nastavku su navedeni frekvencijski pojasevi za koje su se izvlačile značajke u ovome radu:

- 0.5 - 4 Hz,
- 4 - 8 Hz,
- 8 - 13 Hz,
- 13 - 30 Hz,
- 30 - 40 Hz.

To su redom delta, theta, alfa, beta i gama valovi.

Ovaj postupak je napravljen posebno za svaku od 14 elektroda. Na taj način mogu se dobiti razlike tj. bolje informacije od elektroda koje mjere aktivnost mozga u regijama koje su aktivnije kod pokreta ruku.

5.4.2. Ekstrakcija značajki

U ovome koraku cilj je prethodno obrađene podatke na prethodno opisani način pretvoriti u skup značajki koji će se koristiti za treniranje modela. Na ovim obrađenim podacima dobiveno je 120 značajki za svaku od 14 elektroda.

Prvo je izračunata spektralna gustoća snage (PSD). U tome izračunu se također koristi i brza Fourierova transformacija (FFT). Nakon dobivenoga PSD segmenta veličine 129, podijelili smo ga u još manje segmente veličine 10 (12 segmenta, zadnji veličine 9 je odbačen). Za svaki od tih manjih segmenata potom je izračunata apsolutna snaga, relativna snaga i ukupna snaga.

Apsolutna snaga računa se kao zbroj svih 10 vrijednosti segmenta za svaku elektrodu zasebno, rezultat je 14 vrijednosti.

Ukupna snaga računa se kao zbroj svih vrijednosti u tom segmentu, nije napravljen zbroj posebno po elektrodama nego ukupan zbroj. Rezultat je jedna vrijednost.

Relativna snaga dobiva se dijeljenjem apsolutne snage s ukupnom snagom. Apsolutna snaga svake elektrode podjeli se s ukupnom snagom te je ovdje rezultat također 14 vrijednosti, po jedna za svaku elektrodu.

Apsolutna i relativna snaga svakog od 12 manjih PSD segmenta se uzimaju kao značajke za svaku od elektroda. Time se dolazi do broja od $5 * 12 * 2 = 120$ značajki (broj frekvencijskih pojaseva * broj PSD segmenata * apsolutna i relativna snaga).

Ovaj postupak je napravljen odvojeno za svaki skup signala pojedine klase i na skupu za treniranje i na skupu za testiranje. Sve ove značajke zajedno s pripadajućim oznakama klasa ponovno su spojene zajedno. Skup spojenih značajki za treniranje potom je izmiješan kako bi model mogao bolje naučiti na njima i kasnije klasificirati na nevidenim podacima. Testni skup spojenih značajki nije dodatno izmiješan iz razloga što se na njima samo testira model pa nije bitan redosljed podataka.

6. Rezultati i rasprava

U ovome radu napravljene su dvije različite klasifikacije: višeklasna i binarna klasifikacija. Višeklasna klasifikacija je složenije pa je normalno za očekivati kako će rezultati biti nešto lošiji, dok je binarna klasifikacija jednostavnija i daje bolje rezultate. Obije klasifikacije isprobane su na više različitih modela. Za višeklasnu klasifikaciju je napravljena pretraga najboljih hiperparametara za neke od modela kako bi se dobili što bolji rezultati.

6.1. Višeklasna klasifikacija

U ovoj klasifikaciji cilj je raspoznati između tri klase. Klasa 0 predstavlja stanje mirovanja, klasa 1 predstavlja pokret desne ruke dok klasa 2 predstavlja pokret lijeve ruke. Modeli koji su se koristili za ovu svrhu su: stroj potpornih vektora, algoritam slučajnih šuma, XGBoost i duboki model opisan u 3. poglavlju. Oznake podataka kod treniranja i testiranja dubokog modela su "one-hot" enkodirane. Oznaka [0,0] označava klasu 0, oznaka [1,0] označava klasu 1 i oznaka [0,1] označava klasu 2. Izlaz modela su dvije vrijednosti. Svaka od tih vrijednosti prikazuje sigurnost modela da podatak pripada klasi 1 (prva vrijednost) ili klasi 2 (druga vrijednost). Te vrijednosti su između 0 i 1 i označavaju postotak sigurnosti. Kako bi odlučili kojoj klasi pripada podatak postavljen je prag od 0.35. Ako su obije vrijednosti manje od toga praga podatak klasificiramo u stanje mirovanja (klasa 0). Ako su jedna ili obje vrijednosti veće od toga praga uzimamo najveću vrijednost te podatak klasificiramo u pripadajuću klasu. Kod stroja potpornih vektora, algoritma slučajnih šuma i XGBoosta oznake nisu "one-hot" enkodirane pa se ne koristi prag kod njih.

Za duboki model napravljena je pretraga hiperparametara. Hiperparametri koji su se isprobali su:

- Broj epoha - 20, 30, 50,
- Stopa učenja - 0.1, 0.01, 0.001, 0.0001,
- Veličina mini grupe - 8, 16, 20, 32, 64.

Sveukupno 60 različitih kombinacija hiperparametara. Tri modela s najvećim vrijednostima točnosti za duboki model uz točnosti za modele SVM, XGBoost i slučajne šume prikazane su u tablici 6.1. Tablica 6.2. prikazuje rezultate svih mjera za najbolji dobiveni duboki model. Tablice 6.3., 6.4. i 6.5. prikazuju redom rezultate svih mjera za SVM, XGBoost i slučajne šume.

Tablica 6.1. Rezultati višeklasne klasifikacije

Model	Broj epoha	Stopa učenja	Veličina grupe	Točnost
Duboki model	50	0.001	16	0.77
Duboki model	30	0.001	8	0.73
Duboki model	50	0.001	32	0.73
XGBoost				0.69
SVM				0.63
Slučajne šume				0.59

Tablica 6.2. Prikaz mjera najboljeg dubokog modela

Klasa	Preciznost	Odziv	F1-Mjera
0	0.83	0.95	0.88
1	0.76	0.66	0.70
2	0.71	0.69	0.70
Točnost	0.77		

Tablica 6.3. Prikaz mjera SVM modela

Klasa	Preciznost	Odziv	F1-Mjera
0	0.81	0.85	0.83
1	0.57	0.42	0.48
2	0.49	0.60	0.54
Točnost	0.63		

Tablica 6.4. Prikaz mjera XGBoost modela

Klasa	Preciznost	Odziv	F1-Mjera
0	0.84	0.90	0.87
1	0.59	0.61	0.60
2	0.61	0.54	0.58
Točnost	0.69		

Tablica 6.5. Prikaz mjera algoritma slučajnih šuma

Klasa	Preciznost	Odziv	F1-Mjera
0	0.84	0.90	0.87
1	0.42	0.34	0.38
2	0.46	0.51	0.49
Točnost	0.59		

U ovom potpoglavlju smo istražili višeklasnu klasifikaciju za prepoznavanje stanja mirovanja, pokreta desne ruke i pokreta lijeve ruke. Korišteni modeli uključuju SVM, algoritam slučajnih šuma, XGBoost i duboki model. Duboki model se pokazao najboljim s točnošću od 77%, dok je XGBoost postigao točnost od 69%, SVM 63% i najlošije rezultate ima algoritam slučajnih šuma s točnošću od samo 59%.

Detaljna analiza hiperparametara za duboki model omogućila je optimizaciju performansi. Klasifikacijsko izvješće za najbolji model pokazalo je visoku preciznost za klasu mirovanja (0.83), ali nižu za pokrete ruku, što ukazuje na potrebu daljnjeg usavršavanja modela za bolje prepoznavanje tih klasa. Sveukupno, rezultati pokazuju obećavajuće mogućnosti za primjenu ovih modela u praktičnim scenarijima prepoznavanja pokreta.

6.2. Binarna klasifikacija

U ovoj klasifikaciji cilj je raspoznati između samo dvije klase. Klasa 0 predstavlja stanje mirovanja dok klasa 1 predstavlja pokret ruke (lijeve i desne). Za ovaj problem nije se koristio duboki model nego samo SVM, algoritam slučajnih šuma i XGBoost. Razlog tome je što je ovo jednostavniji problem koji ne zahtijeva složenije modele kako bi se dobili dobri rezultati. Tablice 6.6., 6.8. i 6.7. pokazuju rezultate modela za problem binarne klasifikacije.

Tablica 6.6. SVM rezultati

Klasa	Preciznost	Odziv	F1-mjera
0	0.77	0.85	0.81
1	0.91	0.86	0.89
Točnost	0.86		

Tablica 6.7. XGB rezultati

Klasa	Preciznost	Odziv	F1-mjera
0	0.95	0.90	0.92
1	0.95	0.97	0.96
Točnost	0.95		

Tablica 6.8. Slučajne šume rezultati

Klasa	Preciznost	Odziv	F1-mjera
0	0.95	0.88	0.91
1	0.93	0.97	0.95
Točnost	0.94		

Na temelju prikazanih rezultata u tablicama, može se zaključiti kako sva tri modela, SVM, algoritam slučajnih šuma i XGBoost, pokazuju dobre performanse odnosno visoku točnost u klasifikaciji stanja mirovanja i pokreta ruku. XGBoost postiže točnost od 95% što je nešto bolje u usporedbi s algoritmom slučajnih šuma koji postiže točnost od 94% i SVM-a koji postiže točnost od 86%. Ostale mjere, preciznost, odziv i F1-mjera također su nešto bolje kod XGBoost modela. Ovi rezultati pokazuju da, iako problem nije zahtijevao složenije modele, korištenje naprednijih algoritama poput XGBoost-a može pružiti dodatna poboljšanja u izvedbi klasifikacije.

6.3. Moguća poboljšanja

Iako su dobiveni rezultati dobri, postoji prostor za napredak i poboljšanja.

Prvo, u prikupljanju podataka sudjelovao je samo jedan subjekt. Poboljšanje ovoga koraka bilo bi uključivanje većega broja subjekata u eksperiment. Također, raznovrsnost subjekata (različita dob i spol) je važna za bolju reprezentaciju ukupne populacije, a samim time bolju generalizaciju modela i mogućnost šire primjene.

Sljedeće poboljšanje može se napraviti u vidu količine prikupljenih podataka. Povećanjem broja EEG snimanja, model bi dobio više podataka za treniranje isto tako i za testiranje. To bi moglo rezultirati boljim performansama modela.

Podaci za ovaj rad prikupljeni su korištenjem Emotiv EPOC X prijenosnog uređaja s 14 elektrodi. Iako je ovaj uređaj jedan od najboljih komercijalnih EEG uređaja, korištenje EEG uređaja s većim brojem elektroda dobili bi se precizniji signali. Precizniji signali bolje bi predstavili moždanu aktivnost povezanu s pokretima i tako doprinijeli boljim rezultatima.

U ovom radu korišteni su neki tradicionalni modeli strojnog učenja te jedan duboki model. Uporaba još složenijih modela mogla bi dodatno poboljšati rezultate.

Kao nastavak na ovaj rad, bilo bi korisno provesti eksperiment s većim brojem pokreta. Trenutno su analizirani podaci za nekoliko osnovnih pokreta ruku, ali proširenje skupa podataka kako bi uključivao različite tipove pokreta ruku moglo bi pružiti dublji uvid u sposobnosti modela da razlikuje različite motoričke aktivnosti. Na primjer eksperiment bi mogao uključivati dodatne pokrete poput mahanja, pokazivanja prstom i slično.

Sve navedene nadogradnje i proširenje doprinijele bi boljem razumijevanju i klasifikaciji različitih pokreta ruku.

7. Zaključak

U ovome radu istražili smo mogućnosti detekcije pokreta ruku iz EEG signala korištenjem tehnika strojnog učenja. Pregled postojećih istraživanja i rezultati dobiveni u ovome radu pokazuju kako postoji veliki potencijal u ovome području.

Postoji puno različitih tehnika prikupljanja podataka, procesiranja signala, ekstrakcije značajki i modela strojnog učenja koji se koriste za zadani problem. Ne postoji kategorički najbolji izbor za svaki navedeni korak nego sve zavisi o specifičnom problemu koji se obrađuje.

Ovaj rad pokazuje kako na temelju signala dobivenih korištenjem komercijalnog EEG uređaja i korištenjem različitih algoritama strojnog učenja se mogu detektirati pokreti ruku. Dobiveni rezultati, točnost od 95% na binarnoj klasifikaciji i točnost od 77% na višeklasnoj klasifikaciji, su dobri, ali naravno postoji prostor za napredak i daljnja poboljšanja na ovu temu.

Literatura

- [1] G. A. Light, L. E. Williams, F. Minow, J. Sprock, A. Rissling, R. Sharp, N. R. Swerdlow, i D. L. Braff, “Electroencephalography (eeg) and event-related potentials (erps) with human participants”, *Current Protocols in Neuroscience*, sv. Chapter 6, str. Unit 6.25.1–24, July 2010. <https://doi.org/10.1002/0471142301.ns0625s52>
- [2] N. Kulkarni i V. Bairagi, “Electroencephalogram based diagnosis of alzheimer disease”, 01 2015. <https://doi.org/10.1109/ISCO.2015.7282275>
- [3] R. Team, “Brain waves”, *IRJMETS*, 2023. [Mrežno]. Adresa: https://www.irjmets.com/uploadedfiles/paper/issue_3_march_2023/34131/final/fin_irjmets1678212875.pdf
- [4] —, “Brain waves create consciousness”, *International Journal of Development Research*, 2018. [Mrežno]. Adresa: <https://www.journalijdr.com/sites/default/files/issue-pdf/13134.pdf>
- [5] Study.com, “Alpha waves: Definition & lesson - video & lesson transcript”, 2023., accessed: 2024-06-22. [Mrežno]. Adresa: <https://study.com/academy/lesson/alpha-waves-definition-lesson-quiz.html>
- [6] EMOTIV, “Epoc x - 14 channel wireless eeg headset”, 2024., accessed: 2024-06-09. [Mrežno]. Adresa: <https://www.emotiv.com/products/epoc-x>
- [7] Jan Šnajder, “Su1-2022-p08-stroj potpornih vektora”, 2022., accessed: 2024-06-22. [Mrežno]. Adresa: https://www.fer.unizg.hr/_download/repository/SU1-2022-P08-StrojPotpornihVektora.pdf

- [8] S. Ramraj, N. Uzir, R. Sunil, i S. Banerjee, “Experimenting xgboost algorithm for prediction and classification of different datasets”, *International Journal of Control Theory and Applications*, sv. 9, br. 40, str. 651–662, 2016.
- [9] K. H. Kim, W.-J. Choi, i M.-J. Sohn, “Feature importance analysis for postural deformity detection system using explainable predictive modeling technique”, *Applied Sciences*, sv. 12, br. 2, str. 925, 2022.
- [10] L. Breiman, “Random forests”, *Machine learning*, sv. 45, str. 5–32, 2001.
- [11] S. Bhatnagar, L. Gill, i B. Ghosh, “Drone image segmentation using machine and deep learning for mapping raised bog vegetation communities”, *Remote Sensing*, sv. 12, br. 16, str. 2602, 2020.
- [12] A. Altameem, J. S. Sachdev, V. Singh, R. C. Poonia, S. Kumar, i A. K. J. Saudagar, “Performance analysis of machine learning algorithms for classifying hand motion-based eeg brain signals.” *Computer Systems Science & Engineering*, sv. 42, br. 3, 2022.
- [13] M. H. Alomari, A. Samaha, i K. AlKamha, “Automated classification of l/r hand movement eeg signals using advanced feature extraction and machine learning”, *arXiv preprint arXiv:1312.2877*, 2013.
- [14] G. Zhang, V. Davoodnia, A. Sepas-Moghaddam, Y. Zhang, i A. Etemad, “Classification of hand movements from eeg using a deep attention-based lstm network”, *IEEE Sensors Journal*, sv. 20, br. 6, str. 3113–3122, 2019.
- [15] J. Wang, L. Bi, W. Fei, i K. Tian, “Eeg-based continuous hand movement decoding using improved center-out paradigm”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, sv. 30, str. 2845–2855, 2022.

Sažetak

Detekcija pokreta ruku iz EEG signala primjenom strojnog učenja

Sven Rotim

Tema ovoga rada je detekcija pokreta ruku iz EEG signala pomoću strojnog učenja. EEG je metoda snimanja električne aktivnosti mozga koji se koristi u medicini i neuroznanosti. Za ovaj rad su se samostalno prikupili podaci korištenjem Emotiv Epc X prijenosnog EEG uređaja. Ti podaci su zatim procesirani, napravljena je ekstrakcija značajki i potom su istrenirani različiti modeli strojnog učenja kako bi se prepoznali pokreti ruku. Napravljena je binarna klasifikacija (između stanja mirovanja i pokreta ruku) i višeklasna klasifikacija (između stanja mirovanja, pokreta desne ruke i pokreta lijeve ruke). Dobiveni su obećavajući rezultati koji pokazuju veliki potencijal ovoga područja istraživanja.

Ključne riječi: EEG; strojno učenje; pokreti ruku; klasifikacija

Abstract

Detecting hand movement from EEG signals using machine learning

Sven Rotim

The topic of this paper is the detection of hand movements from EEG signals using machine learning. EEG is a method of recording the electrical activity of the brain that is used in medicine and neuroscience. For this work, data was collected using the Emotiv Epoc X portable EEG device. This data was then processed, feature extraction was done and different machine learning models were then trained to recognize hand movements. A binary classification (between resting state and hand movement) and a multiclass classification (between resting state, right hand movement and left hand movement) were made. Promising results were obtained that show the great potential of this area of research.

Keywords: EEG; machine learning; hand movements; classification