

Upravljanje humanoidnim robotom NAO koristeći moždane valove

Vrkić, Ante

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of Science / Sveučilište u Splitu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:166:053334>

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

Download date / Datum preuzimanja: **2024-12-01**

Repository / Repozitorij:

[Repository of Faculty of Science](#)



SVEUČILIŠTE U SPLITU
PRIRODOSLOVNO MATEMATIČKI FAKULTET

DIPLOMSKI RAD

**UPRAVLJANJE HUMANOIDNIM ROBOTOM
NAO KORISTEĆI MOŽDANE VALOVE**

Ante Vrkić

Mentor: Prof. dr. sc. Saša Mladenović

Split, rujan 2024. godine

Temeljna dokumentacijska kartica

Diplomski rad

Sveučilište u Splitu
Prirodoslovno-matematički fakultet
Odjel za informatiku
Ruđera Boškovića 33, 21000 Split, Hrvatska

UPRAVLJANJE HUMANOIDNIM ROBOTOM NAO KORISTEĆI MOŽDANE VALOVE

Ante Vrkić

SAŽETAK

U ovom diplomskom radu se povezuju grane tehnologije iz područja medicine, robotike i umjetne inteligencije kako bih se ostvario projekt upravljanja humanoidnim robotom koristeći svoje misli. Kroz rad je obrađena teorijska osnova potrebna za razumijevanje procesa izrade ovog projekta i mogućnosti za daljnji razvoj. Naglašuje se važnost procesa odabira odgovarajuće opreme, te pažnje pri uzimanju i obradi podataka kako bi se dobili konkretni rezultati. Prolazi se kroz povezivanje samog robota sa ljudskim mozgom koristeći medicinski sigurnu metodu neinvazivnog elektroencefalograma i prikazuje se proces uzimanja moždanih valova iz mozga ispitanika i njihove poveznice s mentalnim naredbama u svrhu upravljanja. U radu je posebna pažnja posvećena važnosti odabira modela umjetne inteligencije baziranom na njihovoj teorijskoj pozadini, te analizom i vizualizacijom njihovih rezultata kako bih se izabrao optimalan model za upotrebu.

Ključne riječi: moždani valovi, NAO, detekcija, robot, EEG, upravljanje, umjetna inteligencija

Rad je pohranjen u knjižnici Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Rad sadrži: [67] stranica, [29] slika i [140] literaturnih navoda.

Izvornik je na hrvatskom jeziku.

Mentor: Prof. dr. sc. Saša Mladenović, redoviti profesor Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Ocjenjivači: Prof. dr. sc. Saša Mladenović, redoviti profesor Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Doc. dr. sc. Goran Zaharija, docent Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Doc. dr. sc. Divna Krpan, docent Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu

Rad prihvaćen: Rujan, 2024.

Basic documentation card

Graduate Thesis

University of Split
Faculty of Science
Department of Informatics
Ruđera Boškovića 33, 21000 Split, Hrvatska

CONTROLLING THE HUMANOID ROBOT NAO USING BRAIN WAVES

Ante Vrkić

ABSTRACT

This thesis connects the branches of technology from the fields of medicine, robotics and artificial intelligence in order to make the project of controlling a humanoid robot using brain waves. The theoretical basis necessary for understanding the process of creating this project and the possibilities for further development is covered in the work. The importance of the process of selecting the appropriate equipment, as well as the care taken when taking and processing data in order to obtain concrete results is emphasized. The thesis shows the connection of the robot with the human brain using the medically safe method of the non-invasive electroencephalograph and explains the process of taking brain waves from the subject's brain and linking them with mental commands of control. Special attention is paid to the importance of choosing artificial intelligence models based on their theoretical background, and analyzing and visualizing their results in order to choose the optimal model for use.

Key words: brain waves, NAO, detection, robot, EEG, controlling, artificial intelligence

Thesis deposited in library of Faculty of science, University of Split

Thesis consists of: [67] pages, [29] images and [140] references.

Original language: Croatian.

Supervisor: Saša Mladenović, Ph.D. Professor at Faculty of Science, University of Split

Reviewers: Saša Mladenović, Ph.D. Professor at Faculty of Science, University of Split
Goran Zaharija, Ph.D. Associate Professor at Faculty of Science, University of Split

Divna Krpan, Ph.D. Associate Professor at Faculty of Science, University of Split

Thesis accepted: September, 2024.

IZJAVA

kojom izjavljujem s punom materijalnom i moralnom odgovornošću da sam diplomski rad s naslovom UPRAVLJANJE HUMANOIDNIM ROBOTOM NAO KORISTEĆI MOŽDANE VALOVE izradio samostalno pod voditeljstvom Dr. sc. Saša Mladenović, U radu sam primijenio metodologiju znanstvenoistraživačkog rada i koristio literaturu koja je navedena na kraju diplomskog rada. Tuđe spoznaje, stavove, zaključke, teorije i zakonitosti koje sam izravno ili parafrazirajući naveo u diplomskom radu na uobičajen, standardan način citirao sam i povezo s fusnotama s korištenim bibliografskim jedinicama. Rad je pisan u duhu hrvatskog jezika.

Student

Ante Vrkić

Sadržaj

1.	UVOD.....	1
2.	UPRAVLJANJE.....	2
3.	ROBOT	4
3.1.	Autonomni i polu-autonomni roboti	4
3.2.	Dijelovi robota	8
3.3.	Područja primjene.....	9
4.	EEG	11
4.1.	BCI	13
4.2.	Moždani valovi.....	17
5.	PROCES IZRADE PROJEKTA.....	21
5.1.	Prikupljanje i obrada podataka	24
5.2.	Treniranje modela.....	26
5.3.	Naivni Bayes Klasifikator	29
5.4.	Stablo Odluke.....	37
5.5.	Klasifikator Slučajne Šume	48
6.	ZAKLJUČAK.....	54
	LITERATURA.....	56
	SLIKE	67

1. Uvod

Mogućnosti kontroliranja robota svojim mislima je koncept koji se odavno prikazuje u filmovima znanstvene fantastike, ali tehnološkim napretkom je ta stvarnost sve bliža. Ovaj rad istražuje zanimljivu poveznicu između neuroznanosti, robota i umjetne inteligencije tako sa sučelje mozak-računalo omogućuje direktnu komunikaciju između ljudskog mozga i vanjskih uređaja. Uz pomoć tehnologije elektroencefalografije, ovaj projekt prikazuje kako specifični uzorci moždane aktivnosti povezani sa raznim mentalnim stanjima mogu kontrolirati humanoidnog robota. Takav tip tehnologije bi napravio potpun napredak kvalitete života za osobe sa invaliditetom.

U ovom projektu se pokušavaju pronaći razlike u različitim mentalnim stanjima kako bih se omogućilo upravljanje robotom koncentrirajući na naredbe za naprijed ili lijevo i prevesti ih u naredbe koje robot izvršava. Ovaj proces uključuje algoritme strojnog učenja koji mogu klasificirati mentalna stanja koristeći podatke moždanih valova pročitanih u stvarnom vremenu koristeći se elektroencefalografom kako bih se naredbe između mozga i robota izvršavale u stvarnom vremenu. Koristi se neinvazivna metoda elektroencefalografa kako bih se stekao uvid u kognitivne procese mozga, ali zbog toga ima i problema sa pouzdanosti iščitanih podataka.

Najveći fokus ovog rada se bazira na istraživanju različitih modela strojnog učenja kao što su Naivni Bayes, Stablo Odluke i Slučajne Šume, kako bi se utvrdilo koji najbolje klasificira podatke moždanih valova. Modeli su izabrani zbog svoje teorijske pozadine mogućnosti klasificiranja bučnih podataka i procjenjuju se na svojoj mogućnosti da povežu komplicirane podatke moždanih valova sa naredbama za robota. Za takve procjene su se koristile metode unakrsne validacije, krivulje učenja i analiza matrice konfuzije. Ovo istraživanje pruža uvid u najefektivniji model za postizanje točnih i brzih upravlja uređaja s ljudskim mislima.

Ovaj rad se dotiče i bitnosti šireg istraživačkog postupka gledajući upravljačke sustave, autonomnu i polu-autonomnu tehnologiju, te napredak elektroencefalografije. Razvojem ove tehnologije sučelja mozak-računalo približavamo se budućnosti lakšeg života za osobe s invaliditetom i revoluciji interakcije čovjeka s digitalnim i stvarnim svijetom. Ovaj rad doprinosi istraživanju mentalnih modela elektroencefalografije i daje nove uvide za praktičnu primjenu sučelja mozak-računalo.

2. Upravljanje

Upravljanje (eng. „Controlling“) u tehnologiji je jedan od temeljni aspekta koji se proteže kroz područja od robotike do raznih softverskih sustava (eng. „Software system“). Ukratko kontrola omogućuje programu ili čovjeku da zadaje ulazne vrijednosti strojevima ili programskim sustavima. S obzirom na primljenu različitu naredbu ili vrijednost izvršavaju se odgovarajuće različite naredbe na temelju tih ulaznih vrijednosti. Upravo to je ključno da bih se osigurala mogućnost tehnološkim uređajima da funkcioniraju na način na koji je njihov rad predviđen. Taj proces upravljanja se s obzirom na primjenu mijenja gledajući različite zadatke sve od programiranja robota za obavljanje preciznih zadataka, vođenja softvera za obradu podataka pa sve do upravljanja autonomnim automobilima. Sustavi koji služe takvu svrhu se mogu nazivati sustavima regulacije (eng. „Control system“) [1]. Svrha takvih sustava je upravo prevođenje ljudskih namjera na način na koji bi ih program ili stroj razumio i odgovarajuće djelovao. Slanjem tih točnih ulaznih vrijednosti ova tehnologija omogućava manipulaciju željenih rezultata. Ova interakcija između ljudskog unosa i reakcije stroja čini samu srž upravljanja u tehnologiji. Takav odnos predstavlja veliku važnost današnje tehnologije zbog osiguravanja učinkovitosti i sigurnosti pri izvedbi.

Kod području robotike upravljanje bi predstavljalo vođenje i nadzor svakog pokreta robota. Svaka radnja koju robot poduzima bazira se na programiranim naredbama. Robot ne može misliti sam za sebe već slijedi posebne instrukcije koje su mu zadane [3]. Ove instrukcije ili naredbe mogu dolaziti direktno iz unosa ili iz algoritama koji obrađuju određene podatke koje robot zaprimi. Nakon obrade tih podataka proslijedi se naredba koja govori robotu da izvrši pojedinu radnju ili skup radnji (sinkronih ili asinkronih) koje će izvršiti određeni zadatak. Preciznost i pravilan redoslijed tih naredbi je od izuzetne važnosti kako bih se izvršili zadatci koji zahtijevaju visoku točnost. Najbolji slučajevi u kojima su potrebni takvi precizni zahtjevi s jako malom tolerancijom na greške i odstupanja se nalaze u proizvodnji procesora i asistirajućih alata u području kirurgije [5]. Bez odgovarajućih preciznih kontrola i nadzora robot bi mogao počinuti greške koje mogu uzorkovati propale proizvode i životnu opasnost.

U softverskom (programskom) okruženju upravljanje donosi jednaku, ako ne i veću važnost. U ovom području fokus je veći na rad s upravljanjem protoka podataka tijekom izvršavanja programa. U tom procesu upravljanja podataka bitno je kontrolirati, odrediti i omogućiti da potrebni podatci budu proslijeđeni u odgovarajuće metode, funkcije i spremljene u njima namijenjene varijable. Primanjem pravih podataka provjere omogućuju pozivanje odgovarajućih naredbi ili skripti koje su unaprijed definirane za izvršavanje od strane adekvatnih unosa od korisničkog unosa (eng. „User input“) [6,7]. Primjer toga bi bio kada se nalazite u korisničkom sučelju (UI, eng. „User Interface“) i kliknete na gumb web stranice. Naredba se tada iščitava i prosljeđuje algoritmu koji ga obrađuje. S obzirom na rezultat obrade korisniku se vraća traženi odgovor ili radnja kao što je otvaranje nove stranice ili prikazivanja željene informacije.

Kontrola je također ključna u trenutnoj automobilskoj industriji. Kako za procese kontrole protoka podataka za računalo u automobilu, tako i u tradicionalnom smislu. Naime u tradicionalnom automobilu sustavi za upravljanje vozila upravljaju funkcijama motora, kočenja i skretanja. Takvi sustavi reaguju na upute od strane vozača (korisnika), poput pritiskanja gasa ili okretanja upravljača. Razvojem tehnologije u automobilima takve radnje su postale samo mali dio sustava upravljanja. Današnjom tehnologijom je došlo do napretka pa automobili imaju sve više senzora. Ti senzori uzimaju različite podatke, te ih moraju obraditi kako bih se prava informacija mogla proslijediti i učiniti željenu naredbu. U trenutnoj tehnološkoj revoluciji takav napredak razvoja automobila je doveo i do autonomno upravljanih automobila. U autonomnim vozilima ulazna naredba (eng. „input“) od strane vozača je postala gotovo nepotrebna, te su ulazne jedinice postale samo od strane senzora koje zadani algoritam upravlja. Ovdje automobil koristi senzore za prikupljanje informacija iz okoline koji su obrađeni u svrhu korištenja sustava za navigaciju, izbjegavanje prepreka i donošenje odluka [2]. Takav sustav regulacije uz mnoštvo senzora i profinjenih algoritama osigurava da automobil slijedi najsigurniju i najučinkovitiju rutu.

Složenost takvih sustava upravljanja može sa vremenom samo rasti kako tehnologija nastavlja napredovati. Javlja se sve veća potreba, ne samo za sofisticiranijim algoritmima već i algoritmima za veći unos podataka, te efikasnu obradu primljene veće količine podataka u upravljačkom sustavu. Zbog toga u području robotike su se počeli primjenjivati napredni senzori koji mogu pratiti manje pomake i umjetna inteligencija koja omogućuje adekvatnu informaciju s obzirom na više primljenih parametara [8]. Upravo zbog te tehnologije roboti sada mogu obavljati delikatne zadatke koji zahtijevaju malu toleranciju na pogreške i suptilne pokrete.

3. Robot

Robot je programibilan stroj s mogućnosti da zamjeni ljudski rad u izvođenju kompleksnih zadataka. Iako je zbog znanstvene fantastike čest nesporazum, roboti ne moraju i često ne izgledaju, niti naliče na ljudska bića. Dolaze u raznim oblicima i veličinama ovisno o njihovoj primjeni i području. Primjer toga je što su industrijski roboti koji sastavljaju automobile izrazito veliki dok sićušni medicinski roboti izvode operacije na ljudskom tijelu [9]. Njihove primjene su široke i raznolike. Razvojem tehnologije roboti su postali sastavni dio modernog društva bilo to u svakodnevnom životu ili u područjima industrije koje su revolucionirali kao što su: automobila industrija, zdravstvena industrija, poljoprivredna industrija, zrakoplovna industrija, logistika i maloprodajna industrija [9-26]. Roboti kao strojevi su dizajnirani za obavljanje zadataka autonomnim procesom ili polu-autonomnim procesom. Sastoje se od raznih komponenti, ali najčešći su: senzori, aktuatori, upravljački sustavi i ponekad umjetna inteligencija (UI, eng. Artificial Intelligence).

3.1. Autonomni i polu-autonomni roboti

Tehnološki napredak dovodi i do većeg razvoja autonomnih i polu-autonomnih robota, te se taj pomak smatra značajnim napretkom u robotici. Daljnjim tehnološkim napretkom granica između autonomnih i polu-autonomnih robota postaje sve teža za odrediti što dovodi do još sofisticiranijih robota sposobnih za obavljanje šireg raspona zadataka uz minimalnu ili nikakvu ljudsku pomoć. Ovaj tip robota je transformirao većinu industrija tako što im je znatno povećao učinkovitost. Osim učinkovitosti doprinio je i znatnom smanjenju rizika za ljudske ozljede u intervenciji opasnih zadataka. Samom primjenom takvih robota se i smanjio stupanj odstupanja i grešaka u složenim procesima što je omogućilo i daljnji razvoj nanotehnologija kojima mali stupanj odstupanja može značiti razliku između tehnički izvedivog i neizvedivog proizvoda [27]. Autonomni i polu-autonomni roboti u svojoj primjeni predstavljaju dva različita pristupa automatizaciji. Odabir pristupa se vrši procesom eliminacije kod uvjeta rada, te njihovih mana, prednosti i razine posljedica od pogreške. Autonomni roboti imaju prednost pri odabiru za zadatke koji zahtijevaju kontinuirani rad, preciznost, sposobnost prilagodbe promjenjivom okruženju bez ljudske intervencije i malu razinu rizika pri pogreškama. Kod odabira autonomnog robota dolazi i problem s visokim troškovima njihovog razvoja, složenošću njihove izvedbe i etičkim problemima zamjene

oduzimanja ljudskih poslova [28-32]. Kod strane polu-autonomnih robota koji nude ravnotežu između automatizacije i nedostatka ljudskog nadzora. Polu-autonomni roboti nude dio automatizacije na zahtjevima za koje su ljudi previše neprecizni i ljudsku kontrolu za ljudski nadzor od grešaka i usmjerenje. S obzirom da ljudska osoba i dalje izvršava posao, ali sa sigurne udaljenosti, to ih čini prikladnima za primjenu u područjima u kojima su sigurnost, fleksibilnost zadatka i ljudska prosudba najvažniji čimbenici [33-37]. Takvi roboti pružaju isplativo rješenje za zadatke koji se ne mogu u potpunosti automatizirati, ali i dalje imaju koristi od tehnološke pomoći. Razumijevanjem različitih mogućnosti, primjena i ograničenja ovih robota može se donijeti informirana odluka koja unaprjeđuje različita područja industrije osiguravajući njihovu učinkovitu i etičku upotrebu koja se uklapa u korist društva.

Autonomni roboti su u biti strojevi koji mogu obavljati zadatke ili operacije bez ljudskog upravljanja ili pomoći. Ovi roboti kombiniraju razne komponente kako bi bili autonomni. Te komponente skupa čine njihov sustav, a može se sastavljati od: senzora, umjetne inteligencije (AI), strojnog učenja (ML, eng. *Machine Learning*) i naprednih algoritama koji im pomažu da razumiju svoje okruženje. Svi ti dijelovi skupa čine autonomni sustav koji ima sposobnost donošenja odgovarajućih odluka s obzirom na zadatak i okruženje i izvođenja radnji na temelju tih odluka kako bih se izvršio zadani zadatak. Autonomni roboti su opremljeni različitim sensorima koji im omogućuju prikupljanje podataka [38-41]. Često, ali ne uvijek ti senzori uključujući i dnevne, noćne i termalne kamere kako bi robot mogao očitavati predmete u različitom okruženju. Korišteni na robotima, a i često popularni na automobilima su sustavi svjetlosnog zamjećivanja i klasifikacije (LiDaR, eng. *Light Detection and Ranging*). LiDaR-i omogućuju robotu da sa laserom za mjerenje udaljenosti napravi mapu svog okruženje s obzirom na to koliko su mu koji predmeti udaljeni [42-44]. Također mogu imati i globalni položajni sustav (GPS, eng. *Global Positioning System*), infracrvene i ultrazvučne senzore za prikupljanje podataka iz svoje okoline. Ovo su samo neki od senzora koji pomažu robotu da bude svjestan svoje okoline tako što otkriva objekte mjerenjem njihove udaljenosti i prepoznavanjem promjena na terenu. Prikupljeni podatci od senzora moraju biti analizirani i obrađeni kako bi robotu bili korisni. Podatke prikupljene od strane senzora obrađuju u njih ugrađena računala. Ta obrada se može vršiti pomoću različitih algoritama i modela umjetne inteligencije [45-48]. Pod ovim korakom se smatra tumačenje osjetilnih informacija iz odgovarajućih senzora za razumijevanje okoline, prepoznavanje predmeta, a

ponekad i predviđanje mogućih promjena u okruženju, te zbog toga i promjena izazova ili zadataka.

Algoritmi donošenja odluka prvo čekaju da se primljeni podatci od senzora analiziraju. Nakon što se podatci analiziraju prosljeđuju se u algoritam za donošenje odluka koji donosi odluku, to jest određuje najbolji smjer poteza djelovanja kako bih se izvršio zadatak. Ovisno o potrebi ovi algoritmi mogu biti od jednostavnih sustava koji se baziraju na određenim pravilima pa sve do složenih modela vođenih umjetnom inteligencijom kako bih mogli učiti iz radnji urađenih u prijašnjim zadacima s obzirom na to koliko su im prošle odluke bile efikasne u rješavanju zadatka [49-51]. Na temelju donesenih odluka robot se mora aktivirati ili pomaknuti. Odluka od algoritma dolazi do aktuatora robota koji je zaslužan za motore i druge komponente na određenom dijelu robota kako bi se izvršila potrebna radnja. Ta radnja može biti pomak cijelog robota na novu lokaciju, pomicanje određenog dijela ili pomicanja određenog predmeta i prilagođavanje smjera putanje kako bi robot izbjegao prepreke na svome putu [52-55]. Roboti upravljani autonomno ponekad znaju imati petlje povratnih informacija. Petlje povratnih informacija robotima omogućuju da mijenjaju svoje odluke s obzirom na prošlo stečena iskustva. Robot s petljom povratnih informacija se ponekad susretne sa neočekivanom preprekom i napravi odluku. Ukoliko je ta odluka bila netočna, robot će sljedeći put za takvu prepreku donijeti drugačiju odluku i tako u krug sve dok ne naiđe na ispravnu [56]. Nakon što robot uradi slijed naredbi koje uspješno zaobilaze prepreku, robot će ubuduće koristiti te naredbe kada se bude susretao sa takvom preprekom. Taj novi naučeni postupak će mu također pomoći pri donošenju novih odluka za rješavanje sličnih zadataka.

Polu-autonomni roboti su sustavi različitih komponenti koji mogu donekle samostalno obavljati određene zadatke. Čimbenik koji ih razlikuje od potpuno autonomnih robota je potreba za ljudskom intervencijom ili nadzor za složenije i kritičnije odluke [34]. Ovi roboti uzimaju najbolje od dvije strane, a to su automatizirane funkcije s robotskom preciznošću kakve čovjek ne može postići i donošenje odluka u svrhu fleksibilnosti i nadzora od strane čovjeka. Ovakvi roboti s ručnim upravljanjem omogućujući fleksibilnost i sigurnost u operacijama u kojima potpuna autonomija nije izvediva ili poželjna zbog visoke razine rizika u slučaju pogreške [57]. Kao i kod autonomnih robota, polu-autonomni roboti koriste svoje senzore kako bi prikupljali podatke iz svoje okoline. Ti se podaci prosljeđuju u računalo gdje se vrši njihova obrada za donošenje odluka obavljanja osnovnih zadataka i navigacije kroz jednostavna okruženja. Polu-autonomni roboti

imaju različite načine rada s obzirom na njihovu izvedbu. Čovjek u petlji (HITL, eng. *Human in the loop*) je najčešći model za rad polu-autonomnih robota. Kod takvog modela čovjek je tako reći sinkroni dio petlje izvršavanja gdje cijeli program čeka njegovu daljnju naredbu. Pri rutinskim zadacima i onima već naučenim od strane polu-autonomnog robota zadatak se obavlja nesmetano poput autonomnog robota jer nema potrebe za ljudskom pomoći. Kada robot naiđe na situaciju za koju nije programiran niti dovoljno sposoban za samostalno donošenje odluka pozvat će ljudskog operatera da provjeri situaciju i napravi daljnju odluku [58]. Robot proslijedi obavijest o nemogućnosti kontrolnoj jedinici. Obavijest može biti jednostavna poruka zahtjeva za pomoć, a može sadržavati i informacije poput prijenosa kamere, mikrofona i vibracija pomoću haptičke povratne informacije. S obzirom na izvedbu čovjek će morati doći na mjesto robota popraviti situaciju sa udaljenosti unijeti slobodnu naredbu ili čak birati između te dvije opcije s obzirom na procjenu složenosti problema. Također neki roboti imaju niz preporučenih radnji za operatera koje može napraviti. U okolnostima autonomnog robota izvršila bi se preporučena radnja sa najvećom šansom uspjeha, ali u osjetljivim područjima gdje greška može biti opasna ili izgubiti velik dio financijskih sredstava bolja je odluka obavijestiti zaduženog operatera sa preporučenim odlukama. Takav zahtjev se može dogoditi kada robot naiđe na prepreku koja se nije mogla predvidjeti pri njegovoj izradi, te je prvi put vidi ili nema niti jedno rješenje niti moguću odluku za donijeti. Polu-autonomni roboti često rade pod modelom rada zvanim zajednička kontrola [59]. U ovakvom modelu rada robot i ljudski operater skupa imaju zajedničku kontrolu nad sustavom. Tada robot obavlja svoju dužnost koju čine jednostavniji poslovi za koje je programiran i samostalan. To omogućuje ljudskom operateru mogućnost biti usredotočen na kvalitetu i pravilnost rješavanja zadatka donošenjem optimalnih odluka i strategiju za skalabilnost i nadogradnju zadanog posla na višoj razini. Model mogućnosti ručnog poništavanja funkcionira tako da je u robotima ugrađena funkcija ručnog preuzimanja upravljanja. To omogućuje operaterima da u slučaju problema mogu preuzeti potpunu ručnu kontrolu nad robotom i upravljati svaki njegov korak kada je to potrebno. Takav model je izuzetno bitan kako bih se osigurala sigurnost u zadacima i poslovima koji zahtijevaju kritične operacije. Alternativan takav pristup se naziva modelom povratnih informacija i komunikacija. U takvom modelu robot konstantno komunicira s ljudskim operaterom osiguravajući zahtjeve i odgovore u stvarnom vremenu [60]. Takvim načinom ljudski operater ima uvid u njegove radnje, upute i prilagodbe kako se izvršavaju, te može preuzeti i preusmjeriti

radnju u stvarnom vremenu ukoliko nešto nije u redu. Robot će u stvarnom vremenu primiti nove naredbe i izvršavati ih kao prioritetne.

3.2. Dijelovi robota

Senzori su uređaji, moduli, strojevi ili podsistemi koji kao ulazne parametre detektiraju promjene u okolini i tu informaciju kao izlazni signal prosljeđuju potrebnom ulazu. Oni omogućavaju robotima da „bude svjesni“ svoga okruženja tako da uzimaju ulazne vrijednosti iz okoline. Ovisno o potrebnom podatku iz okoline se ugrađuje i odgovarajući senzor. Taj senzor može služiti kao detektor razine svjetlosti, temperature, udaljenosti ili zvuka [45, 61-68]. Upravo ta informacija promjene se prosljeđuje i obrađuje u informaciju koja se u algoritmu može koristiti za željene naredbe robota. Primjer je kućni robot usisivač koji za otkrivanje prepreka koristi senzore udaljenosti. Senzor udaljenosti šalje ultrazvučne valove. Senzor prvo pošalje val i odbrojava vrijeme [69-71]. Ultrazvučni val se odbije od najbliže prepreke i vrati nazad do senzora. Nakon toga se računa koliko je vremena prošlo od slanja i povratka vala što nam omogućuje da izračunamo procjenu udaljenosti. Ukoliko je ultrazvučnom valu trebalo duže da se vrati od prijašnjeg očitavanja robot se udaljio od predmeta, a ukoliko je potrebno manje vremena ultrazvučnom valu da se vrati, možemo zaključiti da se robot približio zadnje očitanoj predmetu.

Aktuatori (eng. actuator) su kao mišići robota. To su naprave koje se koriste u mehatronici, robotici i upravljačkoj i regulacijskoj tehnici za stvaranje gibanja kada zaprime odgovarajući signal [72]. Oni su komponente stroja ili robota koje im omogućavaju pomicanje svojih pomičnih dijelova. Bilo to u svrhu samog pomicanja ili manipuliranja sa zadanim objektima [73]. U suštini oni imaju zadatak pretvorbe određene energije u mehaničku. U području robotike to je najčešće pretvaranje električne energije u mehaničku energiju (fizičko gibanje). Na primjer, kako bih robot mogao pomaknuti svoju ruku električni motori u robotskoj ruci to omogućuju pretvaranjem jednog izvora energije u drugi [74]. S današnjim tehnološkim razvojem oni omogućuju robotu da precizno podiže i postavlja predmete. Aktuatori se mogu pronaći u različitim oblicima, poput hidrauličkih klipova, pneumatskih cilindara i električnih motora, Koji će se odabrati ovisi o prikladnoj primjeni za različite vrste težina, pokreta i zadataka.

Prema usporedbi sa ljudskim tijelom sustavi regulacije bi predstavljali mozak. Njihov zadatak je upravljanje, usmjerivanje i regulacija drugih uređaja, dijelova ili sustava koristeći kontrolne petlje

[75]. Sustav regulacije zapravo procesira informacije i donosi odluke koje će se robotske operacije izvršavati. Oni obrađuju informacije koji im senzor proslijedi kao ulazne vrijednosti i vraća naredbu s obzirom na promjene i očitavanja na senzoru. Zatim se ta naredba kao potreban signal prosljeđuje do aktuatora kako bih se učinila određena radnja kao na primjer pomak ruke. Ovi sustavi se razlikuju s obzirom na potrebu okruženja u koji se ugrađuju. Mogu biti jednostavnih daljinski upravljači, regulatori zatvorene petlje, regulatori otvorene petlje, ulazni upravljački sustavi, izlazni upravljački sustavi, više-ulazni više izlazni upravljački sustavi, analogni upravljački sustavi, linearni upravljački sustavi, kontinuirani upravljački sustavi, upravljački sustavi otvorene petlje, distribuirani upravljački sustavi, optimalno kontrolirani, parametarski distribuirani upravljački sustavi, vremenski nepromjenjiv sustav pa sve do naprednih algoritama umjetne inteligencije za upravljačke sustave [76]. Na primjer, upravljački sustav drona obrađuje podatke s GPS-a kako bih se mogla dohvatiti njegova lokacija ili kod naprednijih modela postaviti „stanice“ do kojih bi se po zadanoj naredbi mogao navigirati [77]. Također se obrađuju i informacije akcelerometra kako bi se uzele u obzir informacije brzine vrtnje motora i obradile da bih održao stabilan let.

U robote također možemo ugraditi umjetnu inteligenciju [78]. To ne znači da će robot postati inteligentan već se odnosi na sofisticirane algoritme koji mogu procesirati informacije s izlaznom vrijednosti tako da nalikuju onima do kojih bi i ljudska inteligencija došla [79]. Umjetna inteligencija omogućuje robotima učenje iz već stečenih iskustva, to jest situacija s kojima su se već susreli. S obzirom na ta iskustva mogu donijeti točnu odluku kada se ista ili slična situacija ponovi. Upravo ta mogućnost daje iluziju da su roboti sa umjetnom inteligencijom zapravo inteligentni i omogućuje obavljanje pojedinih zadataka koji obično zahtijevaju ljudsku inteligenciju [80]. Možemo pogledati primjer robota s implementiranom umjetnom inteligencijom u Amazon-ovim skladištima gdje mogu sortirati i organizirati proizvode na temelju situacija koje su naučili iz prethodnih zadataka [81]. Ova prilagodljivost im omogućuje rad u dinamičnim okruženjima gdje zadatci nikad nisu u potpunosti isti, ali su zato identični.

3.3. Područja primjene

Zbog širokog izbora dijelova roboti su izuzetno fleksibilni za rad u različitim granama. U grani medicine roboti se fokusiraju na male i jako precizne korake. Zbog toga pomažu kirurzima u izvođenju delikatnih zahvata pri obavljanju operacija na ljudskom tijelu i smanjuju rizik pogrešaka

koji u tim situacijama predstavljaju razliku između života i smrti [82]. Ti precizni i mali rezovi omogućuju manje oštećenog tkiva i zbog toga osiguravaju ne samo manje vrijeme oporavka, nego i bolje rezultate nakon oporavka. Najpoznatiji kirurški robot za kirurge se zove „Da Vinci Surgical System“ [83]. On omogućuje kirurzima da vrše operacije s zahtjevom najveće preciznosti kroz jako male rezove. Zbog toga se ukloni potreba za rizične, invazivne operacije koje nose veće zdravstvene komplikacije i zbog toga rješava problem dugih i bolnih oporavaka pacijenata. Ovakvi tipovi robota zahtijevaju polu-autonomno upravljanje pomoću konzole od strane kirurga. Oni pretvaraju pokrete ruke od kirurga u precizne radnje robotskih ruku.

U istraživanju svemira roboti poput rovera mogu istraživati daleke planete bez da se šalje čovjek i riskira njegovo život [84]. Takvi roboti se pune sa solarnom energijom od sunca kako bih mogli duže raditi i slati vrijedne podatke natrag na Zemlju. NASA ima poznate rovere na Marsu kao što su roveri: „Curiosity“ i „Perseverance“ [85, 86]. Oni su opremljeni raznim znanstvenim instrumentima za analizu površine Marsa kao što su: lidari, alfa i proton detektori, seizmograf, senzori za temperaturu, senzori za vjetar, senzori za prašinu, senzori za vlagu, razne kamere, spektrometri i mnogi drugi [44, 63, 87-92]. Rade polu-autonomno donoseći odluke o navigaciji i prikupljanju podataka dok ih prate znanstvenici na Zemlji.

Također se roboti mogu primjenjivati u vojsci i policiji gdje koriste robote za izviđanje i uklanjanje bombi što omogućava sigurnost vojnika i policajaca držeći ih na sigurnoj udaljenosti od eksplozije [93, 94]. Također se koristi za nadzor i procjenu opasnosti prostorija zagađenih opasnim kemikalijama i radijacijom. Vojni robot razvijen od firme „iRobot“ se naziva „PackBot“ i ima sposobnost ući u opasna područja i slati vojnicima sa sigurne udaljenosti video prijenos i senzorske podatke u stvarnom vremenu opasnog područja [95]. Opremljen je sa dnevnom i noćnom kamerom, termalnom kamerom, mikrofonom i zvučnikom, sensorima za opasne kemikalije i radijaciju, sensorima za mjerenje udaljenosti, navigacijskim sustavom i rukama sa preciznim aktuatorima. Najčešće se koristi da omogućuje sigurnu analizu, inspekciju i neutralizaciju eksplozivnih naprava u potpunosti uklanjajući opasnost za ljudsko osoblje u svom procesu.

4. EEG

Elektroencefalografija (EEG, eng. *electroencephalography*) ima jako širok raspon korisne primjene u medicinskim i istraživačkim granama [96, 97]. Koristi se za proučavanje normalnih i abnormalnih funkcija mozga. U medicinskoj praksi elektroencefalografija se najčešće koristi za dijagnosticiranje i praćenje raznih neuroloških poremećaja poput alzheimera, psihoze, traume mozga, a najčešće epilepsije [98-101]. Kako elektroencefalografija dohvaća abnormalne signale od moždanih valova koji su povezani s napadajima, izuzetno je korisna liječnicima pri identificiranju vrste epilepsije i pri tome određivanju najboljeg procesa liječenja za pacijenta. Elektroencefalografija se može također koristiti za procjenu moždane aktivnosti kod pacijenata koji imaju poremećaje spavanja [102]. Gledajući iščitane moždane aktivnosti pacijenata doktori mogu utvrditi da li se radi o nesanici, apneji za vrijeme spavanja ili čak narkolepsiji. Snimanjem moždanih valova tijekom spavanja doktori mogu identificirati poremećaje kada ih usporede sa normalnim obrascima spavanja i pružiti odgovarajuće postupke liječenja pacijenta [103-105]. Osim u području medicinske upotrebe elektroencefalografija je vrijedan instrument u području istraživanja kognitivnih neuroznosti. Pri istraživanju u ovom području koristi se elektroencefalografija u svrhu proučavanja funkcija mozga i dubljeg razumijevanja kako različiti dijelovi mozga međusobno funkcioniraju kada su ispitanicima zadani različiti zadatci. Ispitanicima se u tom slučaju daju različiti zadatci poput čitanja, rješavanja matematičkih problema, slušanja glazbe i njima slični zadatci. Elektroencefalograf je posebno koristan za ispitivanje moždane aktivnosti gledajući na jedinicu vremena zbog toga kako precizno očitava aktivacije mozga svaku milisekundu. Tako se mogu prikazati pregledni i točni grafovi u visokoj vremenskoj rezoluciji na kojima istraživači jako lijepo mogu pročitati i proučavati brze kognitivne procese u mozgu [106]. Upravo ta mogućnost praćenja moždane aktivnosti u stvarnom vremenu je glavna prednost elektroencefalografa.

Za razliku od drugih metoda praćenja moždanih aktivacija kao što je funkcionalna magnetska rezonancija (fMRI, eng. *Functional magnetic resonance imaging*) ili pozitronska emisijska tomografija (PET/CT, eng. *Positron emission tomography*), koje imaju vremensko kašnjenje u čitanju moždanih aktivnosti dok elektroencefalograf može snimati moždane valove s vrlo visokom vremenskom rezolucijom [107, 108]. To elektroencefalograf čini posebno korisnim za promatranje i istraživanje vremenski kratkih moždanih procesa. Takvi procesi za promatranje bi bili određeni

zadatci s kratkom fazom rješavanja kognitivnog zadatka ili promatranje napadaja koji se događaju u kratkim vremenskim intervalima. Elektroencefalograf i dalje nije savršen već ima i svoja ograničenja. Najveći nedostatak koji ova tehnologija ima jest loša prostorna rezolucija. To znači da se ne može precizno prikazati izvor pročitanih signala i ne može se onda odrediti točna lokacija iz kojeg dijela mozga dolaze moždane aktivnosti. Na preciznost iščitanih električnih signala koje detektira elektroencefalograf mogu utjecati neizbježivi čimbenici poput lubanje i vlasišta. Zbog toga se mogu iskriviti signali i zbog toga otežati određivanje lokacije njihovog točnog podrijetla. Tako se ograničava sposobnost proučavanja specifičnih moždanih struktura i dubokih regija mozga koje nisu izravno ispod elektroda elektroencefalografa.

Elektroencefalografu je također mana sam način svog rada, a to je iščitavanje elektromagnetskih valova. Teško je i gotovo nemoguće osigurati prostoriju u kojoj jedini elektromagnetski valovi koji se šire zrakom dolaze samo iz moždane aktivnosti. Elektroencefalograf može pročitati te neželjene električne signale koji mogu ometati točno bilježenje moždane aktivnosti [109]. Takvi neželjeni signali mogu biti uzrokovani od malih radnji kao što su pokreti mišića, treptanje očiju ili čak električni valovi koje emitiraju drugi uređaji poput mobitela. Tako se znatno otežava precizno iščitavanje elektroencefalografovih podataka i zbog toga prije analize takvih podataka potrebno je pažljivo čišćenje, te analiziranje podataka kako bi se osiguralo da snimljeni signali točno predstavljaju samo tu moždanu aktivnost [110]. Elektroencefalografu se te mane lako prihvaćaju jer je relativno jeftin i neinvazivan za razliku od metoda kirurške implantacije elektroda direktno u željene dijelove mozga kako bih se sa sigurnošću očitavala aktivnost samo na tom području [111]. Mala cijena, etika i bezbolnost je ono što ga čini popularnim i dostupnim za razna područja kliničkih i istraživačkih primjena. Oprema je lako prenosiva što omogućuje lagano korištenje elektroencefalografa u različitim okruženjima. Koristi se u bolnicama, istraživačkim laboratorijima i kućnim okruženjima za dugotrajno praćenje moždane aktivnosti kod pacijenata ili ispitanika. Također je bitno što elektroencefalograf ne izlaže pacijente zračenju niti zahtijeva unošenje u organizam tvari koji mijenjaju apsorpciju rendgenskih zraka. Zbog toga se smatra sigurnijom opcijom za čestu upotrebu, posebno u ranjivim populacijama kao što su djeca, trudnice i oni starije ljudske dobi.

Elektroencefalografija se također polako integrira u nova područja za svrhu istraživanja i povezivanja ljudskog mozga sa određenim radnjama. Takvo područje se naziva sučeljem mozak-računalo (BCI, eng. *Brain-Computer Interface*). Sučelja mozak-računalo imaju cilj omogućiti

izravne komunikacijske veze između ljudskog mozga i vanjskih uređaja [112]. S tom tehnologijom se razvija mogućnost direktnog povezivanja i upravljanja mozga sa računalom, mehaničkom protezom, robotom ili nekim drugim tehnologijama koje možemo upravljati na daljinu [113, 114]. Sučelje mozak-računalo je temeljeno na elektroencefalografu i ima izrazito visok potencijal za revolucionirati pomoćne tehnologije u svrhu pomoći osobama sa invaliditetom. Ta tehnologija im može pružiti nove načine za interakciju i komunikaciju sa ostatkom svijeta ili im čak omogućiti samostalno obavljanje svakodnevnih zadataka.

4.1. BCI

Sučelje mozak-računalo je tehnologija koja se sa današnjim tehnološkim razvojem brzo širi i postaje dio novih grana. Ta tehnologija omogućava izravnu komunikaciju raznih naredbi preko moždanih valova između ljudskog mozga i vanjskih uređaja. Sučelje mozak-računalo trenutno ima visok potencijal revolucionirati razna područja zanimanja pružajući im nove načine interakcije ljudi s tehnologijom kao što su zdravstvo, rehabilitacija, komunikacija i između ostaloga u svrhe zabave [115]. Sučelje mozak-računalo radi tako da prevodi moždane signale u naredbe koje računalo može razumjeti i obrađivati zaobilazeći tradicionalne metode poput pokreta mišića ili govora. Ta tehnologija omogućuje pojedincima da upravljaju velikim izborom uređaja kao što su osobna računala, prostetski udovi ili čak robotski sustavi koristeći svoje misli. Sučelje mozak-računalo je dizajnirano za čitanje i tumačenje moždanih signala koji se zatim pretvaraju u naredbe radi svrhe upravljanja uređajem. Primarni i teško izvediv cilj sučelja mozak-računalo je omogućiti pojedincima da obavljaju određene zadatke koristeći samo svoje misli. Velika nada u budućnost ove tehnologije se stavlja u mogućnost koristi za osobe s tjelesnim invaliditetom koje imaju poteškoća sa korištenjem svakodnevnih uređaja namijenjenih za prosječnog čovjeka [116]. Sučelje mozak-računalo se oslanja na nekoliko komponenti za svoje učinkovito izvršavanje. Prva bitna komponenta bi bili senzori. Oni se koriste kako bi se otkrili električni signali nastali od moždane aktivnosti. Ti senzori mogu biti neinvazivno postavljeni na vlasište, poput elektroda za elektroencefalografiju, a također mogu biti i invazivni. Popularan primjer takve invazivne metode bi bio Neuralink [117] gdje su elektrode ugrađene direktno u moždano tkivo čovjeka. Postoji širok izbor senzora i odluka, o tome koji će se koristiti ovisno o specifičnom slučaju primjene i potrebnoj razini točnosti za zadani projekt. Nakon što senzor dohvati moždane valove prosljeđuju se u računalni algoritam gdje se obrađuju i prevode u željene naredbe koje uređaj može razumjeti i

izvršiti. Takav proces zahtjeva komplicirane tehnike obrađivanja signala kako bih se filtrirao šum i poboljšao moždani signal što osigurava točniju interpretaciju željene naredbe [118].

Sučelje mozak-računalo svoj rad započinje otkrivanjem moždanih signala. Ti signali se nazivaju neuronski signali. Neuronski signali su u biti električni impulsi koji se stvaraju kada neuroni u mozgu međusobno šalju impulse, to jest komuniciraju. Različite misli ili namjere od čovjeka aktiviraju različite dijelove mozga [119]. To nam omogućuje da vidimo različite vrste neuronske aktivnosti koje senzori otkriju s obzirom na različite misli ili namjere. Na primjer ako se zamišlja pomicanje lijeve ruke generiraju se specifični obrasci moždanih valova koji se mogu identificirati i prevesti u naredbu koja će pomaknuti pokazivač na ekranu ili pomaknuti lijevu robotsku ruku.

Nakon što senzori prepoznaju neki signal, to jest otkriju moždanu aktivnost oni je pojačavaju i digitaliziraju iz analognog ulaza kako bih se signal pripremio za analizu [118]. Taj digitalizirani signal se zatim obrađuje pomoću naprednih algoritama koji mogu identificirati različite uzorke koje povezuju s određenim aktivnostima povezanih za specifičnim mislima ili radnjama. Takvi algoritmi se često temelje na primijenjenim tehnikama strojnog učenja. Strojno učenje omogućuje sustavu da uči iz uzoraka korisnikovih moždanih signala i s više uzoraka kroz vrijeme poboljšava svoju točnost pogađanja. Od obrađenih signala se zatim dolazi do željenih naredbi koje se mogu poslati ciljanom upravljanim uređaju što omogućuje korisniku da zadaje naredbe uređaju služeći se svojim umom.

Postoje različite vrste sučelja mozak-računalo dizajniranih po posebnoj potrebi za specifične aplikacije i potrebe korisnika. Invazivno sučelje mozak-računalo uključuje kiruršku implantaciju elektroda ravno u mozak što omogućuje pružanje signala visoke rezolucije i uklanjanje rizika prikupljanja lažnih pozitivnih signala [120]. Invazivna metoda se ne koristi često zbog toga što nosi značajne zdravstvene rizike kao što su bakterijske infekcije ili trajna oštećenja moždanog tkiva. Za razliku od toga neinvazivno sučelje mozak-računalo koristi vanjske senzore na tjemenu glave poput elektroencefalografa za otkrivanje moždane aktivnosti bez opasnosti zdravlja ispitanika ili pacijenata. Iako su sigurniji i jednostavniji za korištenje također nude i nižu razlučivost signala, te imaju problem osjetljivosti na buku i smetnje [121].

Sučelja mozak-računalo imaju jako širok raspon primjena u različitim područjima. Najčešće i najznačajnije područje primjene je upravo zdravstvo. U zdravstvu se sučelja mozak-računalo primjenjuju za pomoć osobama s invaliditetom ili neurološkim poremećajima [96, 98-106, 113]. Tako sučelje mozak-računalo može pomoći osobama s paralizom određenih udova da povrate

kontrolu nad svojim svakodnevnim okruženjem omogućavajući im da upravljaju računalom, upravljaju invalidskim kolicima ili manipuliraju robotskom rukom koristeći svoje misli kako bih se uvelike poboljšala njihova neovisnost o drugim ljudima i kvaliteta života.

Sučelja mozak-računalo se također razvijaju i istražuju za upotrebu u komunikaciji kako bih se pomoglo pojedincima koji ne mogu govoriti ili se kretati zbog neurodegenerativnih bolesti kao što su amiotrofična lateralna skleroza (ALS, eng. *Amyotrophic Lateral Sclerosis*) ili čak sindrom zaključanosti (eng. *Locked-in syndrome*) [122, 123]. Otkrivanjem moždanih signala povezanih s govorom ili namjerom, sučelja mozak-računalo mogu omogućiti osobama koje boluju od tih bolesti komunikaciju sa odabirom slova na koji se točka ili pokazivač zaustavi ili riječi na ekranu ili čak uz pomoć naprednije tehnologijom generiranjem govora putem računala [2022].

Osim u području medicine sučelja mozak-računalo bolesnim pojedincima mogu potencijalno pomoći svojom primjenom u područjima kao što su videoigre, obrazovanje i vojne operacije. U videoigrama sučelja mozak-računalo mogu ponuditi impresivnije i interaktivnije iskustvo dopuštajući igračima da kontroliraju elemente igre koristeći svoje misli i koncentrirajući svoj um [115]. U području obrazovanja sučelja mozak-računalo bi se potencijalno mogla koristiti za poboljšanje učenja pružanjem povratnih informacija učenika u stvarnom vremenu o njegovoj razini posvećenosti radu ili koncentracije [125-127]. U vojnim okruženjima sučelja mozak-računalo bi mogla omogućiti vojnicima učinkovitije upravljanje bespilotnim letjelicama ili drugim robotskim sustavima pružajući stratešku prednost u složenim i visokorizičnim okruženjima [128]. Iako tehnologija sučelja mozak-računalo se prikazuje izrazito korisnom nudeći obećavajući potencijal razvoja tehnologije treba uvažiti i njene nedostatke. Tehnologija sučelja mozak-računalo suočava se s nekoliko izazova i ograničenja koji se moraju riješiti prije nego što postanu široko prihvaćeni. Jedan od glavnih takvih izazova je njegova točnost i pouzdanost detekcije, te interpretacije moždanih signala. Moždani signali često su očitani kao slabi i neprecizni što otežava razlikovanje uzoraka kod kojih je točnost izrazito bitna od pozadinskih smetnji. Ovaj izazov je posebno naglašen kod neinvazivnih sučelja mozak-računalo. Kod takvih signali moraju proći kroz vlasite i lubanju zbog čega dolazi do daljnje degradacije signala. Do toga dolazi zbog prirode valnih signala kako se odbijaju od prepreke. Ovisno o prepreci, frekvenciji i valnoj duljini, val se može u potpunosti odbiti, a u ovom slučaju val se djelomično odbija. To znači da dio vala koji je prošao gubi svoja unikatna svojstva i zbog toga ga ne može u potpunosti točno očitati kakav je poslan, to jest uzrokovan od neurona [97].

Drugi izazov s kojim se tehnologija sučelja mozak-računalo suočava je potreba za obrazovanjem ili obukom ljudi o korištenju te tehnologije kako bih se svaki korisnik mogao prilagoditi za uporabu. Naime sučelja mozak-računalo u većini slučajeva zahtijevaju od korisnika da prođu određeno razdoblje uvježbavanja i učenja kako bi sustav naučio prepoznati njihove specifične moždane signale. Ovaj proces zna vrlo često biti dugotrajan i nažalost ne rezultira uvijek optimalnim performansama kako bi bio koristan [129]. Također znatan utjecaj imaju čimbenici kao što su umor, stres ili promjene u mentalnom stanju koje mogu utjecati na odstupanje kod moždanih signala [97]. Za kontrolirano okruženje sa iskusnim korisnicima ovo predstavlja manji problem jer s obzirom na prepoznato stanje se mogu podatci rasporediti u odgovarajuće tablice ili ne dodati uopće. Pošto je takve uvijete gotovo nemoguće osigurati sa prosječnim čovjekom i prisutne su te smetnje onda dolazi do varijacija u izvedbi sučelja mozak-računalo i njegove pouzdanosti.

Također postoje problemi etičkih pitanja i zabrinutosti za privatnost korisnika povezanih sa sučeljem mozak-računalo. Kako sučelja mozak-računalo postaju sve naprednija tako postoji mogućnost zlouporabe. Zlouporaba u ovom konceptu bi se odnosila na neovlašten pristup podacima o mozgu pojedinca i napretkom ove tehnologije, strah od manipulacije korisnikovih misli i postupaka. Zbog toga vrlo je bitno osiguravanje sigurnosti i privatnosti podataka o mozgu kako bi se osiguralo sprječavanje ove potencijalne zlouporabe i održavanje povjerenja korisnika pri razvoju ove tehnologije. Upravo zbog ove zabrinutosti članica Sjedinjenih Američkih Država Colorado je 2024. godine donijela prvi zakon zaštite korištenja neuralnih podataka pojedinaca. Ubrzo nakon toga su se pridružile ovoj svrsi i druge članice Sjedinjenih Američkih Država, te je članica California, dok se zakon ne provede, stavila neuralne podatke pod kategoriju „osjetljivih privatnih podataka“. [130]

Unatoč navedenim izazovima budućnost sučelja mozak-računalo se čini obećavajućom s obzirom na kontinuirana istraživanja i samim razvojem usmjerenim na poboljšanje njihove učinkovitosti i proširenosti njihove primjene. Pošto napredni sustavi sučelja mozak-računalo koriste tehnologije strojnog učenja i umjetne inteligencije može se pretpostaviti da će i njihov razvoj igrati ključnu ulogu u poboljšanju preciznosti i pouzdanosti sučelja mozak-računalo razvojem profinjenijih algoritama za obradu signala i prepoznavanje iščitanih uzoraka.

Također za napredak ove tehnologije istražuju se i testiraju novi materijali i tehnologije kako bi se poboljšala udobnost i široka upotrebljivost sučelja mozak-računalo. Trenutno se provodi rad


istraživača o materijalima za elektrode koji su fleksibilniji i imaju sposobnost da dodiranjem ne oštećuju živo tkivo i ne izazivaju alergijske reakcije tako da se mogu ugraditi uz minimalan zdravstveni rizik i nelagodu. Slično takvim metodama napredak u bežičnoj tehnologiji bi mogao omogućiti savršeno čiste i nenametljivije elektrode za sučelja mozak-računalo što bi ih činilo pristupačnijima za svakodnevnu upotrebu.

Kako se sučelja mozak-računalo nastavlja razvijati imaju potencijal totalno transformirati način na koji komuniciramo s tehnologijom tako što nam nudi nove mogućnosti za komunikaciju, kontrolu i rehabilitaciju bolesnih ljudi. Znatnim smanjivanjem prepreka između mozga i vanjskih uređaja sučelja mozak-računalo bi mogla osamostaliti osobe s invaliditetom, poboljšati ljudske sposobnosti u radu s tehnologijom i pružiti nove uvide i spoznaje o radu mozga.

4.2. Moždani valovi

Moždani valovi su oscilirajući električni signali generirani sinkroniziranom aktivnošću stanica koje čine živčani sustav u mozgu, a zovu se neuroni. Neuroni međusobno komuniciraju putem električnih impulsa, a kada se više neurona aktivira zajedno onda se proizvodi signal koji nazivamo moždanim valovima [131]. Ovi moždani valovi mogu se promatrati pomoću elektroencefalografa što znači postavljati elektrode na vlasište kako bi se mjerile električne aktivnosti mozga. Dobiveni rezultati snimke pokazuju uzorke moždanih valova koji se zatim mogu klasificirati u različite vrste moždanih valova temeljenih na njihovoj frekvenciji ili brzine osciliranja. Frekvencija moždanih valova mjeri se u hercima (Hz), a oni predstavljaju broj ciklusa u sekundi.

Postoji pet glavnih vrsta moždanih valova, a to su alfa, beta, gama, delta i theta koji su prikazani na Slika 4.1. Svaka vrsta moždanih valova povezana je s različitim mentalnim stanjima i aktivnostima. Raspon frekvencija moždanih valova kreće se od vrlo sporih valova poput delta valova pa sve do vrlo brzih gama valovi [132]. Proučavajući ove različite uzorke moždanih valova, znanstvenici mogu naučiti više o temi kako funkcionira mozak i kako različita stanja mozga odgovaraju različitim ponašanjima i mentalnim procesima.



Slika 4.1 Moždani valovi

Delta valovi su najsporiji moždani valovi koji imaju frekvencijski raspon od 0,5 herca pa sve do 4 herca. Delta valovi su najčešće povezani s dubokim snom i obično su prisutni u mozgu tijekom okrepljujućih faza sna poznatih kao non-REM (eng. *Rapid Eye Movement*) spavanje. Delta valovi važni su za oporavke i regeneraciju kao i za učvršćivanje sjećanja i obradu emocija. Kada se čovjek nalazi u dubokom snu mozak mu prvenstveno proizvodi delta valove omogućujući tijelu i umu da se odmori i oporavi [133].

Theta valovi imaju frekvencijski raspon između 4 herca i 8 herca. Obično su povezani s laganim snom, opuštanjem i meditacijom. Theta valovi su također prisutni u ranim fazama sna i smatra se da su uključeni u proces sanjanja. Takvi valovi se često promatraju kada je osoba u stanju duboke opuštenosti ili sanjarenja. Također su jako povezani s kreativnošću, intuicijom i emocionalnom obradom. U nekim slučajevima theta valovi su također prisutni tijekom hipnoze [134].

Alfa valovi se kreću od 8 herca do 13 herca i povezani su sa opuštenim, ali budnim stanjem uma. Takvi se valovi obično promatraju kada je osoba budna, ali nije aktivno uključena u bilo koji

posvećeni zadatak. Zbog toga su najbolja očitavanja Alfa valova kada se ispitanici odmaraju zatvorenih očiju ili se bave raznim tihim aktivnostima kao što je čitanje. Alfa valovi često su povezani i s mirnoćom, opuštenošću i osjećajem blagostanja. Zbog takvih korelacija alfa valovi se smatraju bitnom ulogom u smanjenju stresa i anksioznosti tako što predstavljaju opuštena stanja uma [135].

Beta valovi imaju frekvencijski raspon između 13 herca i 30 herca. Oni su povezani s aktivnim razmišljanjem, rješavanjem problema i fokusom. Ovi valovi su najviše prisutni kada je osoba budna i uključena u kognitivne aktivnosti poput proučavanja, analize informacija i donošenja zaključaka. Beta valovi se povezuju i s koncentracijom, pažnjom i visokom razinom mentalne aktivnosti. Njihova prevelika očitavanja često budu znak da je ispitana osoba nemirna, pod stresom ili osjeća tjeskobu jer se smatra da je tada mozak veoma aktivan i forsiran na obradu više informacija nego li može od jednom procesirati [136].

Gama valovi su najbrži moždani valovi s frekvencijskim rasponom od 30 do 100 herca. Ti su valovi povezani s najvišim kognitivnim funkcijama kao što su učenje i pamćenje. Gama valovi se znatno ističu kada je osoba uključena u rješavanje složenih mentalnih zadataka i kada je u trenutcima intenzivnog fokusa. Pojedini istraživači vjeruju da gama valovi igraju ulogu u integriranju informacija u različitim dijelovima mozga što omogućuje koordinaciju različitih kognitivnih procesa [137].

Moždani valovi su izuzetno bitni jer pružaju uvid u to kako mozak zapravo radi i uvid u njegova različita stanja svijesti. Svaka od 5 glavnih vrsta moždanih valova je povezana sa specifičnim mentalnim stanjima. Također promjene u iščitanim uzorcima moždanih valova mogu ukazivati na promjene u raspoloženju, koncentraciji ili kognitivnoj aktivnosti [138]. Proučavajući moždane valove znanstvenici mogu naučiti više o tome kako mozak zapravo radi i kako njegove različite aktivnosti, misli i emocije su povezane s određenim uzorcima pročitanih iz moždane aktivnosti. Istraživači koriste elektroencefalograf za proučavanje moždani valovi i kako se mijenjaju tijekom različitih faza spavanja kod ispitanika. Ispitivanjem uzoraka delta, theta i alfa valova tijekom spavanja znanstvenici dolaze do bolje spoznaje o procesima koji se događaju u mozgu tijekom spavanja i kako ti procesi zapravo doprinose učvršćivanju pamćenja, emocionalnoj regulaciji i cjelokupnom zdravlju [139]. Slično tome elektroencefalograf se također koristi za proučavanje moždanih valova kod osoba s neurološkim ili psihijatrijskim poremećajima kao što su epilepsija, depresija ili anksioznost radi boljeg razumijevanja temeljnih moždanih aktivnosti povezanih s

ovim stanjima uma. Moždani valovi također se proučavaju u područjima kognitivne i bihevioralne neuroznanosti. Ispitivanjem uzoraka beta i gama moždanih valova tijekom zadataka koji zahtijevaju pažnju, rješavanje problema i donošenje odluka, istraživači mogu postići uvid u neuronske mehanizme koji su u samoj osnovi ovakvih kognitivnih procesa. Takvo znanje se može koristiti za razvoj intervencija i terapija za poboljšanje kognitivnih funkcija i kako bih se rješavao kognitivni deficit kod osoba s neurološkim i psihijatrijskim poremećajima.

Proučavanje moždanih valova oslanja se na korištenje elektroencefalografa koji se smatra neinvazivnom tehnikom za očitavanje i mjerenje električnih aktivnosti u mozgu. Elektroencefalograf u ovom slučaju uključuje postavljanje elektroda na vlasište kako bih se otkrili električni signali koje proizvode neuroni [140]. Te su elektrode povezane s elektroencefalografskom izvedbom koja pojačava i zatim bilježi električne signale što omogućuje istraživačima da promatraju preciznije prikazane uzorke moždanih valova.

Kako bismo analizirali uzorke moždanih valova u istraživanjima se koriste tehnike obrađivanja iščitanih signala kako bih se filtrirao šum i poboljšalo očitavanje relevantnih moždanih signala [118]. Takav proces uključuje rascjepkavanje različitih frekvencijskih pojaseva moždanih valova poput delta, theta, alfa, beta i gama valova, te ispitivanje njihove snage i međusobne usklađenosti tih signala. Analizirajući uzorke moždanih valova u različitim uvjetima i zadacima ispitanika, istraživači mogu znatno više saznati o neuronskim mehanizmima koji u svojoj osnovi prikazuju različita stanja svijesti, kognitivnih procesa i ponašanja. Također osim elektroencefalografa za proučavanje moždanih valova mogu se koristiti i druge tehnike kao što su magnetoencefalografije (MEG, eng. *Magnetoencephalography*) i funkcionalne magnetske rezonancije (fMRI, eng. *Functional magnetic resonance imaging*). Magnetoencefalograf mjeri magnetska polja koja proizvode moždane aktivnosti za razliku od funkcionalne magnetske rezonancije koja mjeri promjene u protoku krvi koja je povezana s neuronskom aktivnošću [107, 108]. Ove tehnike pružaju izuzetno korisne informacije o funkcioniranju mozga i mogu se koristiti u kombinaciji s elektroencefalografom za šire i preciznije razumijevanje ljudske moždane aktivnosti.

5. Proces izrade projekta


U svrhu izrade projekta „Upravljanje humanoidnim robotom NAO koristeći moždane valove“ potrebno je odabrati adekvatnu opremu kako hardversku tako i softversku. Potrebno je integrirati pouzdano sučelje mozak-računalo i okruženje za upravljanje robotom. Glavni faktor pri izboru opreme je bila pouzdanost u kvalitetno iščitavanje moždanih valova i efikasno i sigurno okruženje za testiranje kontrole robota.

Kako bih se osiguralo kvalitetno sučelje mozak-računalo potrebno je i prvobitno odabrati kvalitetan elektroencefalograf. Za ovaj projekt je izabrat „MindWave EEG headset“ razvijen od strane tvrtke „NeuroSky“. Izabran je iz razloga što je jedan od neinvazivnih elektroencefalografa koji je lagan za korištenje. Uređaj je veoma lagan i udoban zbog čega je pogodan za korištenje u većim vremenskim periodima. Lako se prenosi i ne zahtjeva nikakva klinička okruženja niti veliko predznanje kako bih se mogao koristiti, a također je jedan od elektroencefalografa koji koristi samo jedan senzor. Elektroencefalografi koji imaju više senzora mogu preciznije prepoznati iz kojeg točno dijela mozga signal dolazi, te zbog toga imaju i više ulaznih jedinica. Kod elektroencefalografa sa samo jednim kanalom iako se dobivaju manje precizniji podatci, lakši su za korištenje zbog protoka kroz samo jedan kanal umjesto odabira i obrade više kanala iščitanih podataka. Ovaj elektroencefalograf omogućuje iščitavanje moždanih valova u stvarnom vremenu što je također ključna specifikacija kako bih se robot mogao upravljati u stvarnom vremenu. Njegov ugrađen filter rješava potrebu za ručnim ograničenjem raspona signala i njegov „ThinkGear“ softver omogućuje dodatne informacije kao što su koncentracija i treptanje. Za razliku od elektroencefalografa koji imaju više senzora je znatno jeftiniji što ga čini znatno pristupačnijim, a u isto vrijeme sasvim dovoljnim u svrhu izrade ovog projekta.

Kao robot je izabran NAO humanoidni robot kojeg je razvio „SoftBank Robotics“. Izabran je zbog toga što je specifično dizajniran za socijalne i interaktivne zadatke, te njegova veličina, mobilnost i humanoidni izgled ga čine idealnim robotom za upravljanje ljudskim mislima u stvarnom vremenu. NAO humanoidni robot je također fleksibilan što se tiče izbora programskih jezika zbog čega ne izaziva problem u slučaju nemogućnosti korištenja elektroencefalografa s određenim programskim jezicima. NAO robot je također već u brojnim istraživanjima korišten u interakciji s ljudima i elektroencefalografom tako da ima i teorijsku osnovu za korištenje u svrhu ovog projekta.

Za sigurno okruženje u kojem se može testirati upravljanje robota bez velikog rizika za nastalom štetom je izabran simulator „Webots“. Ovaj simulator pruža besplatnu uslugu s visokim brojem mogućnosti i prilagodba okruženja. Osim što pruža opciju simuliranja NAO robota pruža i visoku razinu realizma uz svoju implementiranu kinematiku, dinamiku, simulaciju senzora i njihovu povratnu vrijednost u stvarnom vremenu. Podržava brojne programske jezike i skripte pokrenute unutar sebe kao i povezivanje sa lokalnim i udaljenim skriptama kao i ulazne jedinice od vanjskih uređaja u stvarnom vremenu. Simulator „Webots“ osim što podržava programske jezike i API-je kompatibilne s NAO robotom pruža i jednostavnu integraciju istih. Također pruža brzu promjenu okruženja, te interakciju robota s okruženjem u stvarnom vremenu kako bih se parametri brzo mogli prilagoditi u svrhu optimiziranja rada prije implementacije na fizičkom robotu.

Model korišten za prepoznavanje mentalnog stanja nije moguće odabrati u ovoj fazi već će se njegov odabir izvršiti nakon obrade podataka. Nakon odabrane opreme započinje proces izrade projekta. Za pisanje skripti ovog projekta se koristio programski jezik „Python“ verzije „3.9.12“ zbog svoje učinkovitosti kod treniranja modela umjetne inteligencije i kompatibilnosti kroz izabrane opreme. U svrhu preglednije izrade skripti korištene su biblioteke: „pandas“, „numpy“, „matplotlib“, „sklearn“, „json“, „telnetlib“, „threading“ i „socket“. Tijek protoka podataka kroz izvršavanje ovog projekta je prikazan na Slika 5.1.



Slika 5.1 Dijagram protoka podataka

Kako je prikazano na Slika 5.1, izvršavanje započinje s inicijalnim povezivanjem elektroencefalografa i računala. Nakon što povezivanje postane uspješno program automatski iščitava podatke moždanih valova iz glave korisnika. Takvi podatci su sirovi te se trebaju obraditi u oblik koji se može koristiti za klasifikaciju modelom. Nakon obrade podatci su prosljeđeni u model koji daje informaciju o kojem se mentalnom stanju radi. Nakon što je predikcija modela obavljena, ona se mora obraditi u tip podatka koji se može prosljeđiti na server koji omogućuje komunikaciju između skripti iščitavanja i klasificiranja sa skriptom koja će pokrenuti robota. Zatim se informacija sa servera prosljeđuje u skriptu robota gdje je potrebno primljenu informaciju ponovno obraditi kako bih se iz oblika za slanje mogla pretvoriti u oblik za daljnju obradu. Kada je podatak transformiran dolazi u provjeru o kojem se mentalnom stanju radi. S obzirom na utvrđenu mentalnu naredbu poziva se odgovarajuća skripta koju robot slijedi i izvršava zadanu naredbu. Nakon što izvrši naredbu proces se ponovno vraća na očitavanje moždanih valova i proces tako vrti u krug.

5.1. Prikupljanje i obrada podataka

U svrhu ovog istraživanja i izrade projekta upravljanja humanoidnog robota očitanim moždanim valovima sa elektroencefalografom, nisu korišteni dostupni podatci od drugih istraživanja već očitani podatci od strane ispitanika s kratkom pripremom kako bih se utvrdila točnost i pouzdanost. Podatci su se uzimali od strane osam muških ispitanika dobi starosti između dvadeset dvije i dvadeset osam godina s tim da je prosjek starosti ispitanika dvadeset šest godina. Ispitanici su prvo upućeni sa ciljem istraživanja i njegovim postupkom. Ispitanicima je prvo objašnjen način na koji elektroencefalograf uzima podatke i prikazan im je softver sa ugrađenim igrama koje se upravljaju sa „NeuroSky Minwave-om“. Nakon što je ispitanik upoznat sa osnovama, elektroencefalograf je postavljen na njegovu glavu podešavajući odgovarajuću širinu. Elektroda ovog elektroencefalografa se postavlja na čelo ispitanika i uzemljenje se spaja na ušnu resicu njegovog lijevog uha. Nakon uspješnog postavljanja i povezivanja ispitanici su uvježbavani na softveru „App Central for Mindwave“ gdje su proveli deset minuta po jednom zadatku. Ukupno su zadana četiri zadatka. Prvi zadatak je bio „SpeedMath“ u kojemu se testiraju aritmičke sposobnosti ispitanika rješavajući matematičke zadatke. Drugi zadatak je bio „Schulte“ gdje ispitanik pronalazi u tablici izmještane brojeve i odabire ih redosljedom od najmanjeg do najvećeg. Treći zadatak se zove „Find Number“ gdje ispitanik pronalazi zadane brojeve u tablici nasumično poredanih

brojeva. U zadnjem zadatku „Mind Hunter“ ispitanik pokušava podići svoju koncentraciju kako bih naciľjao na zadanu metu.

Nakon ove vježbe ispitanici imaju uvid kako elektroencefalograf reagira na njihove misli i znaju svoj osjećaj stanja uma pri prikazu visoke koncentracije u softveru. Zbog toga se smatraju uvježbanim za fokusiranje na sljedeći zadatak za vrijeme kojega će se uzimati njihovi podatci. Elektroencefalograf je iščitavao podatke iz ispitanika svakih pola sekunde u trajanju od pet minuta po svakom zadatku. Ispitanicima su zadana četiri zadatka sa vremenskom pauzom od pet minuta između svakoga. Ispitanicima je zadana instrukcija da gledaju u predmet na ekranu i koncentriraju se na pomicanje zadanog predmeta lijevo. Instrukcija ispitanicima za drugi zadatak je bila da zamišľjaju ravan put ispred sebe. Za treći zadatak ispitanicima je dana instrukcija da za taj isti ravni put zamišľjaju kako se udaljava, to jest kako bih izgledao da hodaju unatrag. Za četvrti zadatak ispitanicima su zadane jednake instrukcije kao u prvom zadatku, osim što umjesto lijevo se koncentriraju da se objekt pomiče desno i taj proces je ponovljen tri puta.

Pošto se za iščitavanje podataka iz ispitanika koristio elektroencefalograf potrebno je posvetiti pažnju i na iščitane podatke i njihovu točnost. Naime elektroencefalograf iščitava podatke uz pomoć elektrode kao senzora i takvi podatci mogu biti netočni zbog okolnih smetnji pri iščitavanju. Takve smetnje su jedan od razloga zašto se za encefalograf izabrao „Neurosky Mindwave“. Naime elektroencefalograf „Neurosky Mindwave“ ima u sebi ugrađen „ThinkGear Chip“ koji služi kao filter koji pojačava pročitane signale kako bih eliminirao problem odbijanja valova iz neurona od lubanju ispitanika i popravio gubitak signala. Ta tehnologija nam također eliminira potrebu za postavljanjem filtera vanjskih signala. Naime kada elektroencefalograf iščitava moždane valove, postoji šansa da pročita i signale koji su emitirali uređaji iz okoline. Zbog toga bih se za iščitane podatke trebao napraviti filter koji će pročitane frekvencije veće od pedeset herca zanemariti. Iako su podatci prošli već kroz dvije obrade još uvijek se smatraju sirovim ili neobrađenim podacima. Da bi ih mogli koristiti potrebno je pretvoriti ih u format s kojim se mogu pregledno prikazati, analizirati i iskoristiti. Zbog toga su se pročitani sirovi podatci pretvorili u „Json“ format s kojim ih se lako iščitava. Pošto se radi o velikoj količini podataka potrebno ih je staviti u pregledan format tablice, a izabran je „csv“ format radi lakše preglednosti, vizualizacije i treniranja neuronske mreže. Pošto ni tehnologija koju koristi „ThinkGear Chip“ nije savršena kao konačan dio obrade podataka, podatci su pregledani i svako očitavanje u kojem su svi moždani valovi manji od deset tisuća mikrovolta su izbrisani. Takvi podatci se smatraju neispravnim jer kako je

objašnjeno u paragrafu moždanih valova, svi valovi predstavljaju određenu aktivnost. Te aktivnosti uključuju sve od fokusa, rješavanja aritmetičkih zadataka, visoke pažnje, opuštenosti i ostalih. Zbog te spoznaje možemo eliminirati takve podatke jer je nemoguće da ispitanik u isto vrijeme nije niti fokusiran niti opušten, a podatci su premali da bih se uzeli kao sredina između dva ekstrema. „NeuroSky MindWave“ također koristi svoj „eSense“ algoritam koji pruža korisne podatke koji se mogu iskoristiti. Taj algoritam uzima pročitane podatke i analizira ih kako bih došao do postotka pažnje i meditacije ispitanika. Također koristan podatak iz tog algoritma je njegova mogućnost o tome da li je ispitanik trepnuo. Pošto podatci poput alfa valova dolaze do većeg izražaja ukoliko su oči otvorene ili zatvorene, detekcija treptaja je izuzetno važna kako bih se omogućilo iščitavanje točnih podataka. U ovom slučaju je napravljen algoritam koji neće bilježiti iščitane podatke moždanih valova ukoliko „eSense“ algoritam vrati povratnu informaciju da je detektirao treptaj.

5.2. Treniranje modela

Nakon procesa obrade podataka oni se smatraju spremnim za korištenje što je u ovom slučaju treniranje neuronske mreže. Kada sam pristupio zadatku treniranja podataka moždanih valova za prepoznavanje četiri različite mentalne naredbe odlučio sam upotrijebiti modele: Naivni Bayesov Klasifikator (GNB, eng. Gaussian Naive Bayes), Stablo Odluke (eng. Decision Tree) i Slučajne Šume (eng. Random Forest). Izabrani su naravno radi svojih pojedinačnih snaga, kompatibilnosti s traženim izlazima, te najviše zbog njihovih prikladnosti za obradu kompliciranih podataka moždanih valova. Signali elektroencefalografa su sami po sebi bučni, nelinearni i posjeduju složene uzorke zbog kojih je vrlo teško istrenirati dobar model. Naivni Bayes je pri biranju bio atraktivan izbor zbog svoje jednostavnosti i brzine. Naime on pretpostavlja da su karakterističnosti podataka neovisni i normalno raspoređeni. Takav pristup se smatra pojednostavljenim, ali često rezultira u iznenađujuće dobrim rezultatima ukoliko se primjeni na podacima s velikim brojem atributa kao što su upravo podatci moždanih valova očitani sa elektroencefalografom kod kojih postoji zabrinutost od prevelike naučenosti na podacima. U takvim slučajevima model je previše naviknut na podatke na kojima je treniran i zbog toga ukoliko mu novi podatci nisu isti kao oni na kojima je treniran, neće ih pogoditi. Pretpostavka normalizacije i neovisnosti o karakteristikama podataka omogućuje Naivnom Bayesovom klasifikatoru da radi nesmetano čak i s ograničenom količinom podataka za treniranje. Takve prednosti su upravo ono što ga čini odličnim osnovnim

modelom za početak ovog istraživanja. Model Naivnog Bayesovog klasifikatora ne može obećati uspješnost budući da su elektroencefalografova očitavanja rijetko savršena i zbog toga model možda neće u potpunosti obuhvatiti zamršenost temeljnih uzoraka što zahtijeva uzimanje u obzir i drugih metoda.

Za drugu opciju je izbran model Stabla Odluke. Stabla Odluke su ne parametarski modeli koji mogu obraditi nelinearne odnose i interakcije između značajki podataka koje su vrlo uobičajene u očitavanjima sa elektroencefalografom. Rekurzivnim dijeljenjem podataka na temelju njihovih značajki, stabla odluke grade model koji se može lako prilagoditi složenim strukturama podataka bez potrebe za sofisticiranom prethodnom obradom podataka. Stabla odluke također kao i model Naivnog Bayes klasifikatora mogu biti sklona opasnosti prevelike naučenosti na podacima za treniranje. Rizik je pogotovo veći u ovom slučaju gdje se koriste potencijalno bučni podatci upravo zbog njihove tendencije stvaranja vrlo specifičnih grana odluke na podacima za treniranje. Kako je prisutan rizik prenaučnosti modela za dodatno testiranje je dodan i model Slučajne Šume. Njegova metoda treniranja pokušava riješiti ovaj problem prenaučnosti modela tako što umjesto samo jednog stabla odluke gradi više stabala kojima za treniranje dodjeljuje nasumično odabran podskup od ukupnih podataka i uzima njihov prosjek nagađanja kao konačnu izlaznu vrijednost. Ovaj pristup daje bolju mogućnost generalizacije tako što smanjuje varijancu modela i povećava njegovu otpornost na šum i odstupanja kod signala očitanih elektroencefalografom. Klasifikator Slučajne Šume također ima prednost automatskog rukovanja s podacima koji nedostaju, a pružaju mjere važnosti kod predstavljanja uzorka od podatka. Takvo svojstvo može biti ključno za razumijevanje podatka i uvid u to koji su aspekti elektroencefalografovih podataka najvažniji za razlikovanje ovih mentalnih naredbi.

Nakon što su obrađeni podatci i odabrani modeli koji imaju teoretsku potporu da će dati prihvatljive rezultate na ovom tipu podatka, vrijeme je za treniranje modela. Kod prvog treniranja su se mogli primijetiti i prvi problemi koji zahtijevaju podešavanje podataka. Kroz tri trenirana modela pokazao se najbolji rezultat od trideset posto što se smatra neuspjehom zbog jako male statističke prednosti od nasumičnog pogađanja. Nakon ponovnog pregleda ispravnosti podataka pokušalo se ustanoviti koji su podatci toliko slični da je pogodak modela jednak nasumičnom pogotku. Pošto se radi o vrlo kompleksnim podacima vizualno je nemoguće pronaći odstupanje, te se testiralo promjenom količine podataka smanjujući uzorke. Smanjivanjem broja uzoraka i njihovom kombinacijom pokušava se stvoriti uvid u sličnosti pojedinih uzoraka. Nakon

izbacivanja uzorka iz zadatka gdje su ispitanici se fokusirali na to da predmet pomaknu desno, došlo je do znatnog napretka u modelu. Iako se nije radilo o značajnoj promjeni kao kod izbacivanja podataka fokusa na desnu stranu, izbacivanjem uzoraka gdje su ispitanici zamišljali da se kreću unatrag jer također pokazalo dobar napredak u modelu. Kako bih se ustanovilo kojim podacima su pojedini izbačeni podatci slični, trenirali su se modeli od dva uzorka sa kombinacijom jednog od izbačenih podataka i jednog od preostala dva. Testiranjem se pokazalo da problem sličnosti podataka leži u rezultatima gdje su ispitanici se fokusirala na pomicanje objekta lijevo i pomicanje objekta desno. Iako su rezultati bili malo bolji, sličnost podataka se također ustanovila kod podataka iščitanih kada su ispitanici zamišljali ravan put i hod u nazad. Takav problem nastaje kod iščitavanja podataka koristeći elektroencefalograf koji ima samo jedan senzor. Elektroencefalografi koji koriste više senzora mogu prepoznati aktivnosti u različitim dijelovima mozga, s obzirom na to koji je senzor imao najbolje očitavanje. Pošto su moždani valovi mentalnog stanja za pomicanje objekta lijevo i desno vrlo slični zbog ograničenosti na jedan senzor morali su se izbaciti podatci mentalnog stanja za desno. Zbog toga se jednostavno implementiralo da nakon pojedine akcije robot mijenja smjer. Tu je pomogla „eSense“ tehnologija koja detektira treptaj. Kako je već navedeno ukoliko je treptaj detektiran podatci iz elektroencefalografa se ne bilježe i to se može iskoristi tako da ukoliko se očitaju tri uzastopna treptaja, robot će za sljedeću detekciju skretanja ići u suprotnom smjeru.


Kod sličnosti podataka mentalnog stanja za naprijed i nazad se sumnja na problem sličnosti zadatka gdje za naprijed ispitanik zamišlja put naprijed, a za nazad se fokusira kako se taj put odaljava. Za te podatke se također vizualno nije mogla primijetiti razlika između podataka dok se nije pogledao podatak iščitane pažnje od strane „eSense“ tehnologije. Skoro sva iščitavanja su imala visok postotak pažnje. Zbog takvog očitavanja može se dovesti zaključak kako iako sličan zadatak, ispitaniku je bila potrebna veća razina koncentracije zamišljajući tu sliku kako se odaljuje. Zbog toga kako bih se držala veća točnost mreže i očuvale sve planirane funkcionalnosti pokreta robota, implementirala se provjera razine pažnje za hod unatrag. Ukoliko je razina pažnje bila visoka i model vratio povratnu informaciju o mentalnom stanju ravnog puta, prosljedila bih se naredba za unatrag.

5.3. Naivni Bayes Klasifikator

Kao ulaznu vrijednost model je primio osam parametara. Ti parametri su nastali od četiri objašnjena moždana vala tako što se svaki raspon frekvencija vala podijelio na dva dijela. Nakon uspješnog treniranja modela Naivnog Bayesa, da bi se ustvrdila njegova pouzdanost primijenjena je metoda k-struke unakrsne validacije. Metoda unakrsne validacije je jedna od popularnih tehnika za procjenu koliko dobro istrenirani model funkcionira na podacima s kojima se još nije susreo. Funkcionira tako što se skup podataka podijeli u „k“ broj skupova. Zatim se model trenira na „k - 1“ skupova i testira na ostatku podataka. Ovaj proces se ponavlja za svaki skup podataka i kao konačan rezultat se uzima prosjek svih rezultata točnosti od svakog skupa podataka.

U ovom testiranju je uzet „k = 5“ što znači da se skup podataka podijelio na pet različitih skupova. To znači da je model treniran na četiri skupa i testiran na petom skupu podataka. Taj se proces ponavlja mijenjajući skupove za treniranje tako da se uvijek različiti skup koristi za testiranje sve dok se testiranje ne izvrši na svakom od ovih pet skupova. Ovakav proces pomaže u uvjerenju njegove točnosti i smanjuje rizik prenaučivosti modela, a također daje dodatnu potvrdu da nije podnaučiv. Ovakav proces daje bolju procjenu sposobnosti modela za prepoznavanje uzoraka na podacima sa kojima se još nije susreo.

Graf na Slika 5.2 prikazuje točnost Naivnog Bayes modela kroz pet skupova podataka. Svaka točka prikazana na grafu predstavlja točnost modela u procesu gdje je taj skup korišten za testiranje točnosti ovog modela. Na grafu „os X“ prikazuje skupove podataka tako da graf kretanjem u smjeru „X osi“ prikazuje na kojem je skupu graf testiran, a na kojim skupovima je model treniran. „Y os“ na grafu prikazuje točnost modela kao postotak u decimalnom obliku. Ova mjera prikazuje sposobnost modela da s obzirom na uzorak točno pretpostavi o kojem se mentalnom stanju radi.



Slika 5.2 Unakrsna validacija Naivnog Bayesa

Kako je prikazano na Slika 5.2, mjere točnosti prepoznavanja uzorka mentalnog stanja se izmjenjuju po različitim skupovima podataka za testiranje odstupajući između 78,47% i 92,36%. Takvo odstupanje predstavlja prethodno objašnjen problem buke u iščitavanju moždanih valova koristeći neinvazivni elektroencefalograf. Ukoliko se zbroje sve vjerojatnosti točnih nagađanja kroz svih pet skupova podataka i podjele sa brojem skupova „k“, dobije se prosječna vjerojatnost točnosti (eng. Mean Accuracy) ovog modela na novim podacima i ona čini 88,33%. Takav postotak potvrđuje dobar teorijski odabir modela s obzirom na to da su podatci moždanih valova zbog svojih uzoraka i buke poprilično teški za treniranje i prepoznavanje. Ovaj graf i prosjek točnosti prikazuju kako model ima solidnu razinu generalizacije podataka različitih mentalnih stanja i predstavlja dobru neovisnost o podacima na kojima je treniran.

U skupu podataka broj tri na Slika 5.2 se može primijetiti polagan pad točnosti oko četiri posto što bi značilo da su si uzorci podataka moždanih valova različitih mentalnih stanja počeli sličiti. Ukoliko se pogleda skup podataka broj četiri, vidi se još veći pad od punih deset posto. Takav pad

već predstavlja veliku količinu buke na tim podacima za validaciju ili jako visoku sličnost podataka na tom skupu. Napredak sa točke prvog skupa na drugi za dva posto predstavlja solidan početak učenja, ali i koliko su skupovi tri i četiri bili bitni. Naime da su ukupni podatci za treniranje bili jednaki prvom i drugom skupu, imali bi informaciju da je model točan u devedeset dva posto slučajeva. Tada ne bismo imali uvid da modelu otpada značajna točnost od ukupnih četrnaest posto zbog sličnosti ili prekomjerne buke podataka. Zadnja točka skupa podataka prikazuje kako model ponovno kao i na prva dva, ima jasnu razliku za predviđanje različitih uzoraka.

Rezultat ove unakrsne validacije prikazuje da ovaj model ima zadovoljavajuću razinu prepoznavanja uzoraka između različitih mentalnih stanja. Iako razlika najbolje i najgore točnosti nije užasna, također ne predstavlja niti jako lošu dosljednost modela kroz podatke sa većom razinom buke. Također jedan od mogućih razloga je jednostavnost strukture modela Naivnog Bayesa što bi pretpostavilo da su uzorci međusobno neovisni, te da prate jednostavnu Bayesovu distribuciju. Kod podataka moždanih valova koji su dokazani brojnim istraživanjima da imaju svoju korelaciju, ova pretpostavka bi znatno ograničila mogućnost ovog klasifikatora da prepozna razliku između zadanih uzoraka. Zbog prosječne točnosti unakrsne validacije od 88,33% može se zadovoljiti s ovim modelom, ali zbog odstupanja većeg od deset posto u najboljem i najgorem skupu, ne preporučuje se ovaj model za korištenje u okruženjima u kojima je velika mogućnost buke od obližnjih uređaja i gdje greška predstavlja opasnost od ozljede ili velikog financijskog troška.


Matrica zabune (eng. Confusion Matrix) pruža detaljan uvid u to koliko puta model točno i netočno klasificira različite mentalne naredbe. Ovaj pristup pruža uvid u detaljniji rad modela od običnog postotka točnosti kako bih se bolje vidjelo gdje model točno radi pogreške. Matrica zabune je tablica koja dodatno naglašuje performanse klasifikacije modela pokazujući točne vrijednosti i one koje je model nagađao. U binarnom modelu kao na Slika 5.3, koji smo prilagodili ove podatke, matrica zabune ima četiri ključne komponente koje su istinski pozitiv (TP, eng. True Positive), istinski negativ (TN, eng. True Negative), lažni pozitiv (FP, eng. False Positive), lažni negativ (FN, eng. False Negative). Tablica po svoje dvije osi „x“ i „y“ sadrži dvije vrijednosti što su nula i jedan. Na osi „y“ vrijednost nula predstavlja mentalno stanje za naprijed, a jedinica predstavlja mentalno stanje za skretanje. Na osi „x“ nula predstavlja rezultate za koje je model pretpostavio da je stanje za naprijed, a jedinica one za koje je model predvidio stanje za skretanje.

Istinski pozitiv bi bila ćelija 1,1 u tablici što u ovom slučaju podataka bi predstavljalo ukupan broj slučajeva kada je model točno procijenio da uzorak moždanog vala predstavlja naredbu za skretanje. Takvih slučajeva ova matrica prikazuje 159.

Istinski negativ bi bila ćelija 0,0 u tablici što u ovom slučaju podataka bi predstavljalo ukupan broj slučajeva kada je model točno procijenio da uzorak moždanog vala predstavlja naredbu za naprijed. Takvih slučajeva ova matrica prikazuje 109.

Lažni pozitiv bi bila ćelija 1,0 u tablici što u ovom slučaju podataka bi predstavljalo ukupan broj slučajeva kada je model netočno procijenio da uzorak moždanog vala predstavlja naredbu za skretanje. Takvih slučajeva ova matrica prikazuje 37.

Lažni negativ bi bila ćelija 0,1 u tablici što u ovom slučaju podataka bi predstavljalo ukupan broj slučajeva kada je model netočno procijenio da uzorak moždanog vala predstavlja naredbu za naprijed. Takvih slučajeva ova matrica prikazuje 4.



Slika 5.3 Matrica Zabune Naivnog Bayesa

Koristeći podatke iz matrice zabune mogu se izračunati vrlo bitne mjere za procjenu performansi modela. Na Slika 5.4 je prikazana formula za računanje koeficijenta točnosti. Taj koeficijent predstavlja omjer točnih pogodaka (Istinski negativni i Istinski pozitivni) i ukupnih pogodaka (Istinski negativni, Istinski pozitivni, Lažni negativni i Lažni pozitivni).

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

Slika 5.4 Formula za računanje koeficijenta točnosti

Uvrštavanjem vrijednosti iz matrice zabune u svrhu računanja koeficijenta točnosti dobije se jednačba kao na Slika 5.5.

$$\text{Točnost} = \frac{159 + 109}{159 + 109 + 4 + 37} = 0,8673$$

Slika 5.5 Uvršteni parametri za računanje točnosti Naivnog Bayesa

Rezultat ove jednačbe predstavlja točnost ovog modela, to jest da je model 86,73% puta pogodio točan rezultat. Na Slika 5.6 je predstavljena formula za preciznost. Preciznost predstavlja postotak u koliko je slučajeva model bio u pravu kada je pretpostavljao da se radi o naredbi za skretanje.

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

Slika 5.6 Formula za računanje koeficijenta preciznosti

Rezultat ove jednačbe je prikazan na Slika 5.7 i prikazuje da je model u 97,54% slučajeva ispravno pretpostavio da se radi o uzorku moždanih valova za skretanje.

$$\text{Preciznost} = \frac{159}{159 + 4} = 0,9754$$

Slika 5.7 Uvršteni parametri za računanje preciznosti Naivnog Bayesa

Sljedeći parametar koji je potrebno izračunati se naziva koeficijent osjetljivosti i on se računa s formulom prikazanom na Slika 5.8.

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

Slika 5.8 Formula za računanje koeficijenta osjetljivosti

Uvrštavanjem vrijednosti u zadanu formulu se dobije koeficijent osjetljivosti prikazan na Slika 5.9 koji prikazuje u kolikom je postotku slučajeva model prepoznao uzorak moždanih valova za skretanje od svih uzoraka moždanih valova za skretanje. U slučaju ovog modela to je 81,12%.

$$\text{Osjetljivost} = \frac{159}{159 + 37} = 0,8112$$

Slika 5.9 Uvršteni parametri za računanje osjetljivosti Naivnog Bayesa

Koeficijenti preciznosti i osjetljivosti su se računali samo zato kako bih se mogao izračunati F1-Rezultat, a njegova formula je prikazana na Slika 5.10.

$$\text{F1-Rezultat} = 2 \times \frac{\text{Preciznost} \times \text{Osjetljivost}}{\text{Preciznost} + \text{Osjetljivost}}$$

Slika 5.10 Formula za računanje vrijednosti F1-Rezultat

Formula prikazana na Slika 5.10 računa prosječni postotak između koeficijenta preciznosti i osjetljivosti dajući uravnotežen postotak. Takva uvrštena formula za ovaj istrenirani model Naivnog Bayesa izgleda kao na Slika 5.11 i daje rezultat od 88,57%. Ovaj uravnotežen postotak se također može izračunati koristeći negativne vrijednosti iz matrice zabune (TN, FP, FN).

$$\text{F1-Rezultat} = \frac{2 \times 0,9754 \times 0,8112}{0,9754 + 0,8112} = 0,8857$$

Slika 5.11 Uvršteni parametri za računanje F1-Rezultata Naivnog Bayesa


Matrica zabune pokazuje da model Naivnog Bayesa jako dobro prepoznaje razliku između uzoraka mentalnog stanja naredbe za naprijed i za skretanje sa postotkom točnosti od 86,73%. Pokazalo se također da model najčešće griješi kod pogrešnog pogađanja uzorka mentalnog stanja za naredbu

skretanja. Pogriješio je čak trideset i sedam puta što znači da se pojedini uzorci mentalnog stanja za naprijed preklapaju sa uzorcima nekih mentalnih stanja za skretanje.

Koeficijent preciznosti nalaže da model točno predviđa naredbe za skretanje u čak 97,54% slučajeva. Taj postotak predstavlja da u sto predviđenih naredbi za skretanje lijevo će model pogriješiti u svega tri slučaja što je prihvatljivo za ovaj model. U drugu ruku od ukupnih naredbi prepoznat će naredbu za skretanje u 81,12% slučajeva. Pošto je taj postotak znatno manji može se doći do zaključka da je model malo prenaučen na pogađanje naredbe za skretanje.

Konačni postotak F1 za naredbu skretanja iznosi 88,57% što prikazuje izbalansirani pregled i predstavlja model kao poprilično pouzdanim za prepoznavanje uzorka moždanih valova za naredbu skretanja, ali također da može biti unaprijeđen u području pogrešnog pogađanja naredbe za skretanje. Analizom matrice zabune može se zaključiti kako Naivni Bayes model može prepoznati razliku u uzorcima različitih mentalnih stanja za naredbe skretanja i nastavljanja naprijed. Iako ima mjesta za napredovanje uz zadane rezultate se smatra poprilično dobrim modelom, a prije nego li se izabere kao konačni trebaju se ovi podatci iskoristi za treniranje ostala dva modela ukoliko oni mogu prepoznati veću razliku između ova dva uzorka.

Kako bih se bolje naučila dinamika kod procesa učenja klasifikatora Naivnog Bayesa, na Slika 5.12 je prikazan graf s krivuljom točnosti na podacima za treniranje i krivuljom točnosti na podacima za testiranje. Graf prikazuje kako se model razvija kroz tijek treniranja što se više podataka koristi. Ove krivulje daju izuzetno vrijedne informacije o tijeku treniranja i testiranja koje se mogu iskoristiti za dijagnostiku potencijalnih problema kod modela kao što je prenaučenost i podnaučenost. Krivulja točnosti na podacima za treniranje prikazuje s kolikim postotkom točnosti model obavlja predviđanja na podacima na kojima je treniran s obzirom na povećanje količine podataka korištenih za treniranje. Krivulja točnosti na podacima za testiranje prikazuje koliko dobro model prepoznaje uzorke moždanih valova s kojima se još nije susretao s obzirom na povećanje količine podataka korištenih za treniranje.



Slika 5.12 Krivulja učenja Naivnog Bayesa

Na Slika 5.12 os „x“ prikazuje broj podataka na kojima je treniran model Naivnog Bayesa. Točke na krivuljama po svojoj „x osi“ prikazuju na kojoj količini podataka je model treniran u trenutku testiranja za vrijeme treniranja modela. Os „y“ predstavlja postotak točnosti modela u decimalnom obliku. Točke na krivuljama po svojoj „y osi“ prikazuju kolika je bila točnost modela u trenutku testiranja za vrijeme treniranja modela.

Plava krivulja prikazuje točnost na podacima za treniranje. Ta krivulja pri početku pokazuje visok postotak točnosti jer se radi o maloj skupini podataka i zbog toga ih model lako „memorizira“ i pojavi se prenaučenosť. Nakon toga model otpada u točnosti zbog susretanja sa novim tipovima podataka, te kada krene učinkovito razlikovati uzorke moždanih valova pokazuje napredak. Takvo ponašanje je potpuno normalno i očekivano jer nakon susreta s novim podacima model te uzorke ne može savršeno uvrstiti dok se ne prilagodi.


Narančasta krivulja predstavlja točnost na podacima za testiranje. Krivulja pri samom početku prikazuje jako nisku sposobnost pogotka u usporedbi sa plavom krivuljom zbog toga što je model

na maloj količini podataka prenaučeni i ne može efektivno raspoznati uzorke s kakvima se nije susreo. Kako se količina podataka za treniranje povećava, model sve bolje prepoznaje podatke s kojima nije upoznat i točnost se stabilizira sa odstupanjem od jedan posto. Zanimljiv događaj u ovom grafu je rijedak trenutak kada model pogađa bolje podatke za testiranje od onih za treniranje. Nakon toga se dešava ponovni pad ispod krivulje podataka za treniranje s malim odstupanjem od 0,32%. Takav pad ispod krivulje točnosti na podacima za treniranje je očekivan i potvrđuje da model nema značajan problem prenaučivosti na podacima za treniranje. Modeli skoro uvijek rade malo bolja predviđanja na podacima na kojima su učeni u usporedbi s onima s kojima se još nisu susreli tako da se ova razlika smatra normalnom i očekivanom. U slučaju ovog modela poslije treniranja na dvjesto pedeset podataka, krivulja ostaje relativno ista između 88% i 89% što prikazuje da je to i generalna točnost prepoznavanja uzoraka moždanih valova na modelu Naivnog Bayesa.

Stabilizacija točnosti predviđanja kod modela prikazuje da nije prisutan problem prenaučivosti. Također točnost od 88% se smatra prihvatljivom tako da model nema problem niti od podnaučivosti. Ova stabilizacija također prikazuje da nastavak treniranja sa više podataka neće napraviti znatnu razliku točnosti modela. Za bolje rezultate prepoznavanja uzoraka moždanih valova se može koristiti bolji elektroencefalograf kako bih se išitali precizniji podatci i trebalo bih se pokušati istrenirati modele Stabla Odluke i Slučajne Šume kako bih se našlo optimalno rješenje.

5.4. Stablo Odluke

Kako bih se procijenila učinkovitost predviđanja mentalnih modela koristeći Stablo odluke na podacima moždanih valova išitalih elektroencefalografom, skiciran je graf krivulje učenja prikazan na Slika 5.13. Krivulja učenja prikazuje koliko efektivno model Stabla Odluke predviđa različita mentalna stanja povećanjem količine podataka na kojima je treniran. Točke na tom grafu prikazuju koliki postotak uzoraka je model uspješno prepoznao na zadanoj količini podataka. Prikazuje svoje rezultate na dvije krivulje koje predstavljaju postotke točnosti na podacima za treniranje i podacima za testiranje. Testiranjem modela kroz tijek učenja omogućuje uvid u njegov napredak kroz učenje i usporedbu koliko dobro generalizira podatke na kojima je učen i sa kojima se još uvijek nije susreo.




Slika 5.13 Krivulja učenja Stabla Odluke

Na ovom grafu plava linija prikazuje točnost modela na podacima s kojima je već upoznat, a narančasta linija prikazuje točnost modela na podacima s kojima se još nije susreo. Os „x“ predstavlja veličinu do koje količine podataka je model stigao svojim treniranjem, a os „y“ predstavlja postotak točnosti pogađanja podataka u decimalnom obliku.

Prva zanimljiva stvar na grafu krivulje učenja se vidi na krivulji točnosti za podatke na kojima je treniran model. Postotak točnih nagađanja je čak nevjerojatnih sto posto na samom početku. U običnom slučaju ta pojava se smatra normalnom jer na malom skupu podataka se model nije imao priliku susresti sa odstupanjima, te za prvi test pogađa sve uzorke točno zbog privremene prenaučivosti. Problem nastaje zbog toga što se taj postotak ne mijenja, to jest krivulja ostaje ista. Pošto krivulja predstavlja ravnu liniju može se zaključiti da model kroz vrijeme ne napreduje sa povećanjem količine podatka i ostaje prenaučiv. Stablo Odluke prepoznaje podatke na kojima je treniran toliko dobro da se može reći i da ih je naučio napamet. Pošto svaki uzorak nije savršeno jednak i želimo da se model nauči na ta odstupanja, ovakvi rezultati se smatraju izrazito lošim.

U ambicioznom pogledu takva ravna linija može predstavljati savršen model, ali taj ambiciozan pogled propada zbog narančaste krivulje koja prikazuje podatke s kojima se model još nije susreo. Linija točnosti pretpostavke modela Stabla Odluke započinje znatno niže, kao što je očekivano, ali se niti ne približava sto postotnoj točnosti. Iako različit, postotak točnosti na podacima s kojima se model nije susreo se ne smatra lošim. Prva točka krivulje prikazuje točnost od 88,89% na pedeset sedam podataka što se čini jako dobrim. Iz takvog postotka se može zaključiti kako je model Stabla Odluke vrlo dobro započeo obavljanje svoga zadatka. Zatim krivulja pokazuje rast na drugu točku od 90,70% pa sve do treće točke koja prikazuje 91,67% točnih pogodaka. Do tada bih se moglo zaključiti da se model bolje privikuje na zadane uzorke, ali nakon toga ima pad. Pošto se radi o testnim podacima, takav pad može predstavljati susretanje sa podacima novih odstupanja ili da nastavlja svoje treniranje na podacima sa većim utjecajem šuma. Krivulja točnosti podataka sa kojima se model još nije susreo završava sa 90,72% kao svoju konačnu točnost što se i ne smatra mnogo loše.

Ovako visok i konstantan postotak na podacima za treniranje predstavlja problem previsoke kompleksnosti stabla do te mjere da model uči uzorke napamet. Takav rezultat također može značiti da se model naučio na previše specifičnim uzorcima za tu skupinu podataka, što također spada pod prenaučenosť. Znakove prenaučenosť modela Stabla Odluke ne treba ignorirati i odbaciti, dapače takav uvid treba iskoristiti za mijenjanje hiperparametara. Jedan od parametara koji će se promijeniti kako bih se pokušao riješiti ovaj problem je maksimalna dubina stabla. Ograničenjem maksimalne dubine stabla uzima se pod kontrolom kompleksnost do koje stablo može ići. Takav postupak onemogućuje modelu Stabla Odluke da se nauči na specifične uzorke iz podataka za treniranje što može spriječiti prenaučenosť. U ovom slučaju gdje maksimalna dubina stabla ne prelazi tri, promatraju se krivulje na grafu učenja na Slika 5.14.




Slika 5.14 Krivulja učenja Stabla Odluke na dubini 3

Nakon smanjenja maksimalne dubine stabla na tri, vidi se očit napredak na podacima za treniranje. Krivulja točnosti na podacima za treniranje ne samo da nije zapela na sto posto već je pala blizu krivulje točnosti za podatke sa kojima se model još nije susreo. Iako je točnost na podacima za treniranje manja nego na prošlim dubinama, ovaj rezultat je upravo ono što se tražilo jer prikazuje dokaz da model više ne pamti napamet podatke niti specifične uzorke već uči kako bolje prepoznavati podatke moždanih valova od raznih mentalnih stanja. Model je samo na prvoj točki imao točnost od sto posto što se i očekuje, te se od osme do desete točke vidi blaga stabilizacija modela. Iako analizom grafa bi mogli zaključiti da treniranjem na više podataka bi se mogla odrediti bolja točnost, ova dubina je riješila problem prenaučnosti modela.

Krivulja točnosti na podacima sa kojima se model još nije susreo je također prikazala dobar napredak. Krivulja započinje sa istom točkom kao i kod modela sa neograničenom dubinom i raste do svoje četvrte točke na 90,14%. Taj skup od četiri točke prikazuje kako je model pronašao uzorke na kojima može efikasno prepoznavati moždane signale. Nakon toga se nalazi blagi pad na petoj i

šestoj točki što može značiti da se model susreo sa podacima novih uzoraka ili podacima zagađenim bukom. Nakon šeste točke graf prikazuje optimalan rast i završava na postotku točnosti od 91,67% što je za cijelih jedan posto bolje od prvog modela. Iako jedan posto se ne čini mnogo i izgleda kao da se model Stabla Odluke nije mnogo poboljšao, bitno se fokusirati na omjer te dvije krivulje. Ovaj smanjeni razmak između krivulje postotka točnosti na podacima na kojima je treniran i krivulje točnosti na podacima sa kojima se još nije susreo, prikazuje napredak rješavanja problema prenaučivosti. Ne samo zbog smanjenog razmaka nego i zbog toga što na samom kraju grafa krivulje napreduju u jednakom smjeru. S tim možemo zaključiti kako je model pronašao odgovarajuće uzorke za prepoznavanje moždanih valova neovisnih o tome da li je na njima treniran ili ne. Također su krivulje puno glađe što znači da bi model imao velike koristi od veće količine podataka i znatno se privikao na buku na podacima. Ovaj model ne samo da više nema problem prenaučivosti već se prikazuje obećavajućim da uz više podataka za treniranje bi se spojile ove dvije krivulje i stabilizirale. U takvom slučaju ovaj bi model bio idealan.

Graf validacije modela Stabla Odluke na Slika 5.15 prikazuje kako se model mijenja što se dublje silazi u njegovo stablo odluke. Kod podataka pročitanih od strane elektroencefalografa s ciljem prepoznavanja različitih mentalnih modela, ova krivulja vizualizira kako model generalizira različite uzorke s obzirom na povećanje kompleksnosti modela. Za razliku od prošlog grafa učenja u ovom grafu os „x“ predstavlja dubinu stabla, a os „y“ predstavlja njegovu točnost. Pri niskim dubinama stabla ovaj model je relativno jednostavan, te ne može generalizirati kompleksne uzorke moždanih valova. Takva pojava inače rezultira u niskim postotcima točnosti na podacima za treniranje i podacima za testiranje što predstavlja podnaučivost. To se dešava kada je model prejednostavan, te ne može pronaći odgovarajući uzorak za generaliziranje različitih mentalnih stanja. Povećanjem dubine stabla također se povećava rizik od postizanja prenaučivosti. U ovom slučaju najbolja sredina između problema podnaučivosti i prenaučivosti, to jest, najoptimalnija performansa modela je na maksimalnoj dubini stabla tri.



Slika 5.15 Krivulja validacije modela Stabla Odluke po dubini

Kao što se vidi na Slika 5.15, ovaj model trenutno nema niti preveliku opasnost od prenaučivosti jer postotak točnosti nije toliko ekstremno visok, a nema ni problem podnaučivosti jer je postotak točnosti zadovoljavajući za potrebe ovog modela. Plava krivulja predstavlja krivulju točnosti na podacima za treniranje po dubini stabla, a narančasta krivulja prikazuje točnost po dubini stabla na podacima sa kojima se model još nije susreo. Krivulja točnosti po dubini stabla na podacima na kojima je model treniran započinje sa 89,13%, te raste prema drugoj točki na postotak točnosti od 93,33%. Krivulja završava na trećoj točki sa rastom od jedan posto i tu završava na maksimalnoj dubini od 94,27%.

Krivulja točnosti kroz dubinu stabla na podacima s kojima se model nije susreo započinje na prvoj točki sa 88,06% i raste do druge točke od 91,53%. Krivulja završava sa svojim padom od jedva pola posto na trećoj točki od 91,11%. Analizom ove dvije krivulje može se zaključiti kako je model započeo sa jako dobrom generalizacijom jer je imao visok postotak od 89,13% na plavoj krivulji i 88,03% na narančastoj. Ti postotci nisu mali pogotovo za podatke iščitane elektroencefalografom

sa samo jednim senzorom, a nisu niti preveliki da bih upućivali na problem prenaučivosti. Također dokaz da nije prisutan problem prenaučivosti prikazuje mala razlika između podataka na kojima je treniran i s kojima se nije susreo od samo jedan posto. Zatim se prikazuje rast na drugim točkama ove dvije krivulje koji također prikazuje malu razliku od samo jedan i pol posto. Na trećim točkama ove dvije krivulje se već može uočiti problem zbog čega je model zaustavljen na ovoj dubini. Naime razlika između točke na plavoj i narančastoj krivulji je prerastao tri posto što je trostruko veća razlika točnosti na podacima s kojima se model nije susreo i onim na kojima je treniran u zadnjoj točki. Gledajući Slika 5.15 može se primijetiti da je to upravo granica kada bih se model počeo previše učiti na podacima za treniranje i stvarati opasnost od totalnog neprepoznavanja podatka s kojima se nije susreo ili bar smanjen postotak svoje točnosti na njima. S tim se ponovno potvrđuje da su hiperparametri modela optimalno postavljeni kako bih model dao najbolje rezultate.


Da bih se postigao detaljniji uvid u rad modela Stabla Odluke na predviđanju različitih mentalnih stanja crta se matrica zabune. To je zapravo tablica s kojom se naglašuje koliko dobro model radi pokazujući vrijednosti koje model predviđa i one koje su zapravo točne. Na ovakvom tipu podataka i zahtjevima, matrica zabune ima četiri ključne komponente koje su Istinski pozitiv (TP, eng. True Positive), Istinski negativ (TN, eng. True Negative), Lažni pozitiv (FP, eng. False Positive), Lažni negativ (FN, eng. False Negative). Matrica zabune na Slika 5.16, na svojim osima „x“ i „y“ sadrži dvije vrijednosti što su nula i jedan. Na osi „y“ su prikazane istinite vrijednosti danog uzorka tako da nula predstavlja mentalno stanje za naprijed, a jedinica predstavlja mentalno stanje za skretanje. Na osi „x“ su predstavljene vrijednosti u koje je model klasificirao zadane uzorke tako da nula predstavlja rezultate za koje je model pretpostavio da je stanje za naprijed, a jedinica one za koje je model predvidio stanje za skretanje.

Istinski pozitiv bi bila ćelija 1,1 u tablici što u ovom slučaju podataka bi predstavljalo ukupan broj slučajeva kada je model točno procijenio da uzorak moždanog vala predstavlja naredbu za skretanje. Takvih slučajeva ova matrica prikazuje 157.

Istinski negativ bi bila ćelija 0,0 u tablici što u ovom slučaju podataka bi predstavljalo ukupan broj slučajeva kada je model točno procijenio da uzorak moždanog vala predstavlja naredbu za naprijed. Takvih slučajeva ova matrica prikazuje 127.

Lažni pozitiv bi bila ćelija 1,0 u tablici što u ovom slučaju podataka bi predstavljalo ukupan broj slučajeva kada je model netočno procijenio da uzorak moždanog vala predstavlja naredbu za skretanje. Takvih slučajeva ova matrica prikazuje 19.

Lažni negativ bi bila ćelija 0,1 u tablici što u ovom slučaju podataka bi predstavljalo ukupan broj slučajeva kada je model netočno procijenio da uzorak moždanog vala predstavlja naredbu za naprijed. Takvih slučajeva ova matrica prikazuje 6.



Slika 5.16 Matrica Zabune Stabla Odluke

Koristeći podatke iz matrice zabune za model Stabla Odluke, mogu se izračunati vrlo bitne mjere za procjenu performansi modela. Uvrštavanjem vrijednosti iz matrice zabune u formulu za točnost iz Slika 5.4, dobije se jednadžba prikazana na Slika 5.17

$$\text{Točnost} = \frac{157 + 127}{157 + 127 + 19 + 6} = 0,9191$$

Slika 5.17 Uvršteni parametri za računanje točnosti Stabla Odluke

Rezultat jednadžbe sa Slika 5.17 predstavlja točnost ovog modela u decimalnom obliku od 0,9191, to jest da je ovaj model u 91,91% slučajeva pogodio točan rezultat. Kao i kod modela Naivnog Bayesa nastavljaju se računati ostale vrijednosti. Kako bih se izračunala preciznost modela Stabla Odluke u formulu sa Slika 5.6 će se uvrstiti zadane vrijednosti iz matrice zabune kako je prikazano na Slika 5.18.

$$\text{Preciznost} = \frac{157}{157 + 19} = 0,8921$$

Slika 5.18 Uvršteni parametri za računanje preciznosti Stabla Odluke

Rezultat ove jednadžbe u decimalnom obliku je 0,8921 što govori da je model u 89,21% slučajeva ispravno pretpostavio da se radi o uzorku moždanih valova za skretanje. Zatim za računanje osjetljivosti se primjenjuje formula sa Slika 5.8. U nju se uvrste vrijednosti ove matrice zabune i to izgleda kao na .

$$\text{Osjetljivost} = \frac{157}{157 + 6} = 0,9632$$

Slika 5.19 Uvršteni parametri za računanje osjetljivosti od modela Stabla Odluke

Rezultat u decimalnom obliku prikazuje 0,9632 što znači da su se podatci za skretanje prepoznali u 96,32% slučajeva. Konačno nakon svih izračunatih vrijednosti računa se F1-Rezultat formulom sa Slika 5.10 i to je prikazano na Slika 5.20.

$$\text{F1-Rezultat} = \frac{2 \times 0,8921 \times 0,9632}{0,8921 + 0,9632} = 0,9258$$

Slika 5.20 Uvršteni parametri za računanje F1-Rezultata od modela Stabla Odluke

Rezultat modelovog F1-Rezultata je u decimalnom obliku izračunat na 0,9258 što predstavlja postotak od 92,58%. Takav rezultat predstavlja izuzetno dobar omjer ravnoteže između koeficijenta točnog pogađanja naredbe za skretanje i koeficijenta prepoznate naredbe za skretanje od svih uzoraka koji predstavljaju akciju skretanja.

Matrica zabune pokazuje da model Stabla Odluke jako dobro prepoznaje razliku između uzoraka mentalnog stanja naredbe za naprijed i za skretanje sa postotkom točnosti od 91,91%. Pokazalo se

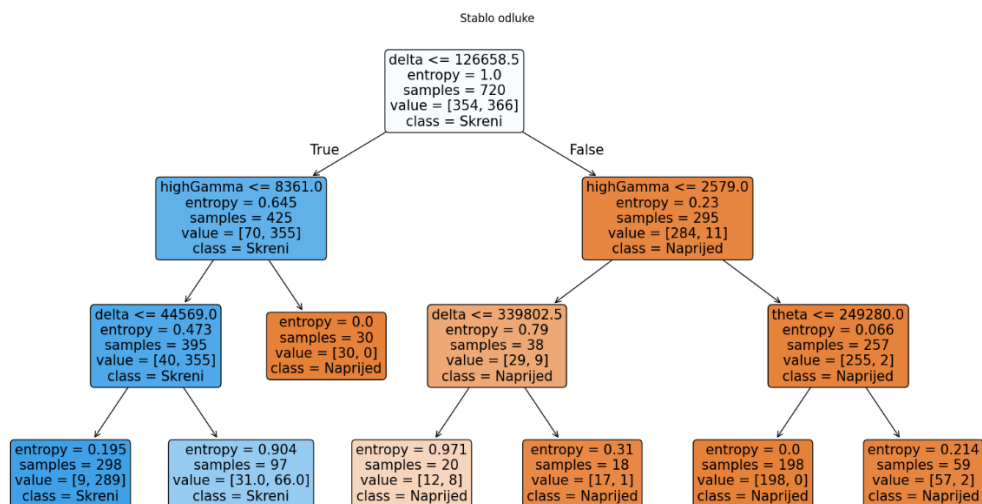
također da model najčešće griješi kod pogrešnog pogađanja uzorka mentalnog stanja za naredbu skretanja gdje je pogriješio devetnaest puta što znači da se pojedini uzorci mentalnog stanja za naprijed preklapaju sa uzorcima nekih mentalnih stanja za skretanje. Takav zaključak se poklapa i kod analiziranja modela Naivnog Bayesa.

Koeficijent preciznosti nalaže da model točno predviđa naredbe za skretanje u 89,21% slučajeva što je za osam posto manje nego model Naivnog Bayesa. U drugu ruku od ukupnih naredbi za skretanje prepoznat će se točno naredba za skretanje u 96,32% slučajeva. Takav rezultat je znatno bolji u usporedbi s modelom Naivnog Bayesa što predstavlja da se smanjenjem parametara maksimalne dubine stabla riješio problem prenaučivosti modela, te unaprijedio s obzirom na prethodni. Iako se takav zaključak smatra pozitivnim, podatak da je model u devetnaest slučajeva pogrešno predvidio naredbu za skretanje nalaže da ovaj model se još uvijek može unaprijediti. Taj napredak bih se mogao ostvariti boljim filtriranjem podataka za treniranje i detaljnim uređivanjem parametara modela.

Konačan postotak F1-Rezultata za naredbu skretanja iznosi nevjerojatnih 92,58% što ne samo da prikazuje izbalansirani pregled i predstavlja model kao poprilično pouzdanim za prepoznavanje uzorka moždanih valova za naredbu skretanja, već i da je model Stabla Odluke za cijelih četiri posto bolji od modela Naivnog Bayesa. Analizom matrice zabune može se zaključiti kako ovaj model može efikasno prepoznati razliku u uzorcima različitih mentalnih stanja za naredbe skretanja i kretanja naprijed. Iako ima mjesta za napredovanje uz zadane rezultate se smatra poprilično dobrim modelom i boljim od prethodnog. Prije nego li se izabere ovaj model kao konačni potrebno je analizirati i zadnji odabran model u ovom istraživanju kako bih se ustanovio najbolji.

Stablo odluke je prikazano na Slika 5.21 kao dijagram koji donosi odluke rekurzivnim dijeljenjem podataka s obzirom na vrijednosti koje predstavljaju. Kada se stablo vizualizira, svaki pravokutnik vizualizira čvorove stabla. Ti čvorovi predstavljaju odluku ili uvjet postavljen s obzirom na ulazne podatke, a grane predstavljaju izlaznu vrijednost te odluke ili uvjeta. Stablo započinje od svog korijena, to jest prvobitnog čvora, i dijeli se na grane koje vode ili do ostalih čvorova odluke ili do listova koji predstavljaju izlaznu vrijednost predviđanja ovog modela. U slučaju prilagodbe ovog modela na klasifikaciju dva različita mentalna stanja, model obrađuje komplicirane podatke od elektroencefalograma kako bih mogao donositi odluke. Primjer takve obrade je u korijenu stabla uvjet „delta $\leq 126\ 658,5$ “ gdje delta valovi predstavljaju glavni uzorak moždanih valova za

inicijalnu podjelu ovog stabla. Ukoliko je iščitan podatak delta vala manji ili jednak 126 658,5 mikrovolti, podatci se prosljeđuju u lijevu stranu stabla. Ukoliko je iščitan podatak delta vala veći od 126 658,5 mikrovolti podatci se prosljeđuju u desnu stranu stabla. Stablo se takvim postupkom nastavlja granati u nove čvorove sve dok ne dođe do lista gdje je konačni rezultat odabran.



Slika 5.21 Stablo odluke

U svakom čvoru i listu se prikazane njegove informacije kako bih se lakše razumjele odluke koje je model napravio. Prva informacija je dijeljenje kriterije (eng. Splitting Criterion) i ona prikazuje uvjet modela za dijeljenje podataka u čvoru. Dijeli podatke s obzirom na odabran najbitniji uzorak za klasifikaciju zadanog podatka u trenutnom dijelu stabla.

Druga informacija u čvoru stabla odluke se naziva entropija (eng. Entropy) i ta informacija govori o tome koliko su podatci u zadanom čvoru čisti ili koliko je model nesiguran u svoju pretpostavljenu odluku. Broj entropije se piše u decimalnom obliku i kreće se u rasponu od 0,0 do 1,00 gdje nula predstavlja potpuno čiste podatke. Potpuno čisti podatci znače da su podatci u tom čvoru svi pripadnici iste klase, to jest istog rezultata klasifikacije. Tako da bih broj jedan predstavljao savršenu podjelu u kojoj pola podataka pripada jednoj klasifikaciji, a ostala polovica drugoj. U slučaju ovog modela to bih značilo da od sto podataka u čvoru pedeset ih predstavlja mentalnu naredbu za naprijed, a ostalih pedeset mentalnu naredbu za skretanje.

Treća informacija u čvoru stabla odluke se naziva uzorcima (eng. Samples) i ta informacija govori o tome koliko podataka je došlo do tog čvora. Kako se u korišćenju vizualiziranog stabla nalaze svi podatci, oni se ovisno o kriteriji dijeljenja granaju u različite čvorove. Zbog toga su prosječno u svakom sljedećem čvoru pedeset posto manji nego u prethodnom i tako se smanjuju dok ne dođu do lista u kojem je klasifikacija konačna.


Četvrta informacija u čvoru stabla odluke se naziva vrijednosti (eng. Value) i ta informacija govori o tome koliki broj od ukupnih podataka čvora pripada pojedinoj klasifikaciji. Ta informacija je prikazana u obliku niza gdje prvi broj prikazuje broj podataka za naredbu skretanja, a drugi za naredbu naprijed. Primjer je u korišćenju stabla na Slika 5.21, gdje piše „value = [354, 366]“ i označava da se u početnom čvoru nalazi 354 podataka moždanih valova za mentalnu naredbu naprijed i 366 podataka moždanih valova za mentalnu skretanja lijevo.

Peta informacija u čvoru stabla odluke se naziva klasom (eng. Class) i ta informacija govori o tome u koju bi klasu ovaj model klasificirao trenutni podatak s obzirom na količinu podataka te klase u zadanom čvoru. Na primjeru vizualiziranog stabla u njegovom čvoru model predviđa da se radi o klasifikaciji naredbe za skretanje jer četvrta informacija čvora nalaže da se u njemu nalazi dvanaest podataka za naredbu kretanja naprijed više nego li podatka za naredbu skretanja.

5.5. Klasifikator Slučajne Šume

Kao prvu metodu analiziranja efikasnosti modela Slučajne Šume primijenjena je metoda k-struke unakrsne validacije. Skup podataka je podijeljen u „k“ broj skupova i zatim se model trenira na „k-1“ skupova i testira na ostatku podataka. Ovaj proces se ponavlja za svaki skup podataka i kao konačan rezultat se uzima prosjek svih rezultata točnosti od svakog skupa podataka. U ovom testiranju je uzet „k = 5“ što znači da se skup podataka podijelio na pet različitih skupova. Pet skupova se koristilo u istoj metodi kod točnost modela Naivnog Bayesa, te je i proces jednak.

Slika 5.22 prikazuje točnost modela Slučajne Šume kroz pet skupova podataka i svaka točka prikazana na grafu predstavlja točnost modela u procesu gdje je taj skup korišten za testiranje točnosti ovog modela. Na grafu „os X“ prikazuje skupove podataka tako da graf kretanjem u smjeru „X“ osi prikazuje na kojem je skupu graf testiran, a na kojim skupovima je graf treniran. Os „Y“ na grafu prikazuje točnost modela kao postotak u decimalnom obliku. Ova mjera prikazuje sposobnost modela da s obzirom na uzorak točno pretpostavi o kojem se mentalnom stanju radi.



Slika 5.22 Unakrsna validacija modela Slučajne Šume

Graf prikazuje točnost unakrsnom validacijom na Slika 5.22 za model Slučajne Šume kroz 5 skupova, te prikazuje veliku stabilnost i izuzetno dobru točnost klasifikacije podataka moždanih valova. Prva točka grafa prikazuje vrijednost od 94,44% točnosti, te raste za tri posto na drugu točku koja čini 97,22%. Nakon druge točke se dešava očekivan pad zbog varijacije podataka uzrokovane bukom od pet i pol posto. Na trećoj točki to čini 91,67% na kojem se postotku zadržava i na četvrtoj točki. Na zadnjoj točki se postotak točnosti na krivulji ponovno vraća na prvobitni postotak od 94,44%. Uočavanjem zadržavanja jednake vrijednosti na trećoj i četvrtoj točki, također primjećivanjem jednake vrijednosti prve i zadnje točke može se zaključiti kako ovaj model ima izuzetno mala odstupanja što dokazuje njegovu konzistentnost pri klasifikaciji različitih mentalnih stanja. Također njegov najniži postotak točnosti od 91,67% i najviši od 97,22% nalažu kako su mu odstupanja na prihvatljivoj razini i vrlo visokoj točnosti. Takvi rezultati prikazuju model Slučajne Šume kao trenutno najbolji model za ovu upotrebu, no da bih se to moglo sa sigurnošću zaključiti potrebno je pogledati i detaljan pregled podataka u matrici zabune.


Matricom zabune na Slika 5.23 se prikaže bolji uvid u to koliko je model Slučajne Šume efikasan u svom klasificiranju uzoraka moždanih valova. Matrica zabune na svojim osima „x“ i „y“ sadrži dvije vrijednosti što su nula i jedan. Na osi „y“ su prikazane istinite vrijednosti danog uzorka tako da nula predstavlja mentalno stanje za naredbu naprijed, a jedinica predstavlja mentalno stanje za naredbu skretanja. Na osi „x“ su predstavljene vrijednosti u koje je model klasificirao zadane uzorke tako da nula predstavlja rezultate za koje je model pretpostavio da je mentalno stanje za naredbu naprijed, a jedinica za one koje je model prevideo stanje za naredbu skretanja. Tako se može vidjeti koliko je puta model točno klasificirao uzorke za naredbu skretanje, a koliko je puta zamijenio sa naredbom za naprijed.

Ćelija 1,1 od matrice zabune (Slika 11) predstavlja Istinit pozitiv. Istinit pozitiv (TP, eng. True Positive) je broj svih slučajeva kada je model točno procijenio da uzorak moždanog vala predstavlja naredbu za skretanje, a ima ih 153.

Ćelija 0,0 od matrice zabune predstavlja Istinit negativ. Istinit negativ (TN, eng. True Negative) je broj svih slučajeva kada je model točno procijenio da uzorak moždanog vala predstavlja naredbu za naprijed, a ima ih 138.

Ćelija 1,0 od matrice zabune predstavlja Lažni pozitiv. Lažni pozitiv (FP, eng. False Positive) je broj svih slučajeva kada je model netočno procijenio da uzorak moždanog vala predstavlja naredbu za skretanje, a ima ih 8.

Ćelija 0,1 od matrice zabune predstavlja Lažni negativ. Lažni negativ (FN, eng. False Negative) je broj svih slučajeva kada je model netočno procijenio da uzorak moždanog vala predstavlja naredbu za naprijed, a ima ih 10.



Slika 5.23 Matrica zabune za model Slučajne Šume

Ukoliko se uvrste iščitani podatci u formulu sa Slika 5.4, može se izračunati omjer točnih klasifikacija naredbi od strane modela i ukupnih kao na Slika 5.24.

$$\text{Točnost} = \frac{153 + 138}{153 + 138 + 8 + 10} = 0,9417$$

Slika 5.24 Uvršteni parametri za računanje točnosti od modela Slučajne Šume

Rezultat jednadžbe sa Slika 5.24 predstavlja točnost ovog modela u decimalnom obliku od 0,9417, to jest da je ovaj model u 94,17% slučajeva pogodio točan rezultat. Ukoliko se u formulu sa Slika 5.6 uvrste vrijednosti iz matrice zabune sa Slika 5.23, dobije se koeficijent preciznosti koji govori o tome koliko je puta model Slučajne Šume bio u pravu kada je nagađao da se radi o naredbi za skretanje. To je prikazano na Slika 5.25.

$$\text{Preciznost} = \frac{153}{153 + 8} = 0,9503$$

Slika 5.25 Uvršteni parametri za računanje preciznosti od modela Slučajne Šume

Rezultat ove jednadžbe u decimalnom obliku je 0,9503 što govori da je model u 95,03% slučajeva ispravno pretpostavio da se radi o uzorku moždanih valova za skretanje. Uvrštavanjem vrijednosti u formulu sa Slika 5.8 dobije se koeficijent osjetljivosti koji predstavlja koliko često je model Slučajne Šume prepoznao uzorak moždanih valova za skretanje od svih uzoraka moždanih valova za skretanje i to je prikazano na Slika 5.26.

$$\text{Osjetljivost} = \frac{153}{153 + 10} = 0,9387$$

Slika 5.26 Uvršteni parametri za računanje osjetljivosti od modela Slučajne Šume

Rezultat jednadžbe sa Slika 5.26 u decimalnom obliku prikazuje 0,9387 što znači da su se podatci za skretanje prepoznali u 93,87% slučajeva. Uvrštavanjem vrijednosti u formulu sa Slika 5.10 dobije se koeficijent F1-Rezultat koji predstavlja prosječni postotak između izračunatog koeficijenta preciznosti i osjetljivosti dajući uravnotežen postotak. To je prikazano na Slika 5.27.

$$\text{F1-Rezultat} = \frac{2 \times 0,9503 \times 0,9387}{0,9503 + 0,9387} = 0,9444$$


Slika 5.27 Uvršteni parametri za računanje F1-Rezultata od modela Slučajne Šume

Rezultat uvrštene jednadžbe za F1-Rezultat je u decimalnom obliku izračunat na 0,9444 što predstavlja postotak od 94,44%. Takav rezultat predstavlja do sada najbolji omjer ravnoteže između koeficijenta točnog pogađanja naredbe za skretanje i koeficijenta prepoznate naredbe za skretanje od svih uzoraka koji predstavljaju akciju skretanja.

Dobiveni rezultati pokazuju koliko je model Slučajne Šume bolji na podacima moždanih valova od Stabla Odluke i Naivnog Bayes modela. Što se tiče točnosti, model je dobio rezultat od 94,17% s kojim je nadmašio model Naivnog Bayesa za osam posto razlike, a model Stabla Odluke za cijelih tri posto. Također je nadmašio ostale modele sa svojim F1-Rezultatom gdje je bio bolji od

modela Naivnog Bayesa za pet i pol posto, a od modela Stabla Odluke za dva posto. S takvim rezultatima je konačan izbor kao najbolji model za klasifikaciju moždanih valova.

Slika 5.28 prikazuje koji su podatci najviše utjecali na odluku predviđanja kod modela Slučajne Šume, te prikazuje delta valove kao najutjecajnije za razlikovanje dva različita mentalna stanja kroz podatke pročitane elektroencefalografom. Ovo pokazuje da i mali valovi niskih frekvencija mogu imati visoko značenje kod prijenosa informacija. Drugi najutjecajniji val se prikazao kao gama val i to specifično u višem dijelu njegovog frekvencijskog pojasa. Delta valovi su povezani sa visokom relaksacijom i dubokim snom, a s obzirom na uputstva dana ispitanicima pri uzimanju njihovih podataka da za naredbu naprijed zamišljaju ravan put, može se zaključiti da su se ispitanici tijekom tog zadatka se znatno opustili, te da je delta val povezan sa naredbom kretanja za naprijed. Upravo tako su gama valovi povezani sa vrlo zahtjevnim kognitivnim funkcijama, a ispitanicima su zadana uputstva da zamišljaju predmet kako se pomiče u stranu. S obzirom na rezultate, ispitanici su se vjerojatno iznimno jako koncentrirali zamišljajući da taj predmet pomiču sa svojim mislima i zbog toga je elektroencefalograf iščitavao visoka očekivanja gama valova.



Slika 5.28 Graf utjecaja podataka na odluku modela Slučajne Šume

6. Zaključak

Istraživanje provedeno u diplomskom radu „Upravljanje Humanoidnim Robotom Nao Koristeći Moždane Valove“ pokazuje mogućnosti za budućnost upravljanja robota koristeći sučelja mozak-računalo bazirana na elektroencefalografu uz pomoć strojnog učenja. Analiziranjem i obradom podataka moždanih valova pročitanih elektroencefalografom ovaj projekt uspješno prevodi kognitivne signale mozga u naredbe koje robot može prepoznati i izvršiti. Odabirom modela strojnog učenja s teorijskim osloncem za ovakav tip podataka se prikazalo vrlo uspješnim zbog toga što su svi imali prihvatljive rezultate.

Eksperimentalnom procjenom modela Naivnog Bayesa se dobio jednostavan i efikasan model koji je imao većih poteškoća u prepoznavanju kompleksnih uzorka moždanih valova s obzirom na svoju konkurenciju. Model Stabla Odluke je imao velik problem prenaučivosti zbog uzimanja vrlo specifičnih dijelova uzoraka podataka, ali se promjenom parametara kao što je podešavanje njegove dubine taj problem sredio. Iako je teoretski znatno više sposobniji za prepoznavanje podataka koji nisu linearni, model Stabla Odluke se pokazao tek malo efektivnijim modelom od modela Naivnog Bayesa na kraju. Zadnji model Slučajne Šume se pokazao izvrsnim kombinirajući većeg broja stabala odluka. Prikazao je impresivno smanjena odstupanja prilikom testiranja dok je pružao vrlo visok postotak točnosti u svojoj klasifikaciji moždanih stanja. Sa svojim postotkom točnosti od 94,17% se prikazao kao najefikasnijim modelom za prepoznavanje mentalnih stanja koristeći moždane valove iščitane sa elektroencefalografom u svrhu upravljanja sa robotom.

Ovim istraživanjem nisu prikazane samo mogućnosti u koje se mogu koristiti podatci moždanih valova za upravljanje s robotima već je ovo istraživanje pokazalo i koliko je bitno ne uzeti samo jedan model strojnog učenja već imati proces selekcije od više odabranih modela koji pružaju teorijsku potporu za svoj odabir na prepoznavanju mentalnih modela uz moždane valove. Rezultati su pokazali kako napredni modeli poput Slučajne Šume mogu unaprijediti pouzdanost sučelja mozak-računalo, tako što im potencijalno postavlja temelje za sofisticiranije upravljačke sustave koji funkcioniraju u stvarnom vremenu.

Ovaj rad doprinosi eksponencijalno rastućem području sustava mozak-računalo naglašujući njihovu praktičnu primjenu u robotici. Integracija ovakvih sustava za davanje naredbi robotu baziranih na moždanim podacima pročitanim u stvarnom vremenu koristeći elektroencefalograf daje visok potencijal napredovanja interaktivne tehnologije između čovjeka i robota, tehnologije

za pomoć ljudima sa invaliditetom i budućnost razvoja autonomnih i polu-autonomnih robota. Ovo istraživanje bi moglo potaknuti nove inovacije tehnološkim napretkom tehnologije iščitavanja moždanih signala koje bi nas približile budućnosti gdje ljudi s lakoćom kontroliraju robote.

Literatura

- [1] "Feedback and control systems" - JJ Di Steffano, AR Stubberud, IJ Williams. Schaums outline series, McGraw-Hill 1967
- [2] "Feedback Control of Dynamic Systems" - Gene Franklin, J. Da Powell, and Abbas Emami-Naeini
- [3] Almutairi, N.B., Chow, M.-Y., & Tipsuwan, Y., 2001. Network-based controlled DC motor with fuzzy compensation. The 27th annual conference of the IEEE industrial electronics society (IECON 01), Vol. 3 (pp. 1844–1849). Denver, CO
- [4] Nilsson, J., 1998. Real-time control systems with delays. Ph.D. dissertation, Lund Institute of Technology
- [5] "Robot assisted surgery: da Vinci Surgical System". Brown University Division of Biology and Medicine, 2007
- [6] Stallings, W. (2000). Data & computer communication. Upper Saddle River: Prentice-Hall
- [7] M. Boasson, "Control systems software," in IEEE Transactions on Automatic Control, vol. 38, no. 7, pp. 1094-1106, July 1993
- [8] Z. Lv, R. Lou and A. K. Singh, "AI Empowered Communication Systems for Intelligent Transportation Systems," in IEEE Transactions on Intelligent Transportation Systems, vol. 22, no. 7, pp. 4579-4587, July 2021
- [9] Isak Karabegović. The Role of Industrial Robots in the Development of Automotive Industry in China. International Journal of Engineering Works , 2016
- [10] Rawassizadeh, R., Sen, T., Kim, S.J. *et al.* Manifestation of virtual assistants and robots into daily life: vision and challenges. *CCF Trans. Pervasive Comp. Interact.* **1**, 163–174 (2019)
- [11] Khan, A., Anwar, Y. (2020). Robots in Healthcare: A Survey. In: Arai, K., Kapoor, S. (eds) Advances in Computer Vision. CVC 2019
- [12] Gonzalez-de-Santos, P.; Fernández, R.; Sepúlveda, D.; Navas, E.; Emmi, L.; Armada, M. Field Robots for Intelligent Farms—Inhering Features from Industry. *Agronomy* 2020

- [13] Bogue, R. "The growing use of robots by the aerospace industry", *Industrial Robot*, 2020
- [14] Bogue, R., "The role of robots in logistics", *Industrial Robot*, Vol. 51 No. 3, pp. 381-386, 2024
- [15] Bogue, R., "Strong prospects for robots in retail", *Industrial Robot*, Vol. 46 No. 3, pp. 326-331, 2019
- [16] De Gauquier, L., Brengman, M., Willems, K., Cao, H.-L. and Vanderborght, B., "In or out? A field observational study on the placement of entertaining robots in retailing", *International Journal of Retail & Distribution Management*, Vol. 49 No. 7, pp. 846-874, 2021
- [17] Shamout, M., Ben-Abdallah, R., Alshurideh, M., Alzoubi, H., Kurdi, B & Hamadneh, S., A conceptual model for the adoption of autonomous robots in supply chain and logistics industry. *Uncertain Supply Chain Management*, 10(2), 577-592, 2022
- [18] Zanchettin AM, Ceriani NM, Rocco P, Ding H, Matthias B, Safety in human-robot collaborative manufacturing environments: metrics and control. *IEEE Trans Autom Sci Eng* 13(2):882– 893, 2016
- [19] Cherubini A, Passama R, Crosnier A, Lasnier A, Fraisse P, Collaborative manufacturing with physical human–robot interaction. *Robot Comput Integr Manuf* 40:1–13, 2016
- [20] Bayram B, İnce G, *Advances in robotics in the era of Industry 4.0*. Springer, Cham, pp 187–200, 2018
- [21] Zhu W, Qu W, Cao L, Yang D, Ke Y, An off-line programming system for robotic drilling in aerospace manufacturing. *Int J Adv Manuf Technol* 68(9-12):2535– 2545, 2013
- [22] Leali F, Vergnano A, Pini F, Pellicciari M, Berselli G, A workcell calibration method for enhancing accuracy in robot machining of aerospace parts. *Int J Adv Manuf Technol* 85(1-4):47–55, 2016
- [23] Hollingum, J., "Robots in agriculture", *Industrial Robot*, Vol. 26 No. 6, pp. 438-446., 1999
- [24] Kyrarini, M.; Lygerakis, F.; Rajavenkatanarayanan, A.; Sevastopoulos, C.; Nambiappan, H.R.; Chaitanya, K.K.; Babu, A.R.; Mathew, J.; Makedon, F. A Survey of Robots in Healthcare. *Technologies* 2021

- [25] VERCELLI, Alessandro et al. Robots in Elderly Care. DigitCult - Scientific Journal on Digital Cultures, [S.l.], v. 2, n. 2, p. 37-50, mar. 2018
- [26] Gamal, A., & Mohamed, M., A Hybrid MCDM Approach for Industrial Robots Selection for the Automotive Industry. Neutrosophic Systems With Applications, 2023.
- [27] Malik, S.; Muhammad, K.; Waheed, Y. Nanotechnology: A Revolution in Modern Industry. Molecules 2023
- [28] Frey C.B., The Technology Trap, 2019
- [29] Tiell, S., Create an Ethics Committee to Keep Your AI Initiative in Check , 2019
- [30] Ethics of Artificial intelligence – S.M.Liao
- [31] Leimanis A, Palkova K. Ethical guidelines for artificial intelligence in healthcare from the sustainable development perspective, 2021
- [32] Henry JV, Oliver M. Who will watch the watchmen? The ethico-political arrangements of algorithmic proctoring for academic integrity, 2022
- [33] Jentsch F., Evans A. W. III, Feldman M., Hoelt R. M., Rehfeld S. A., Curtis M., A scale MOUT facility for studying human-robot interaction and control. Proceedings of the 24th Army Science Conference, 2004
- [34] Chadwick, R. A., Operating Multiple Semi-Autonomous Robots: Monitoring, Responding, Detecting. Proceedings of the Human Factors and Ergonomics Society Annual Meeting, 2006
- [35] M. Rubagotti, T. Taunyazov, B. Omarali and A. Shintemirov, "Semi-Autonomous Robot Teleoperation With Obstacle Avoidance via Model Predictive Control," in IEEE Robotics and Automation Letters, vol. 4, no. 3, pp. 2746-2753, July 2019
- [36] Squire, P. N., & Parasuraman, R., Effects of automation and task load on task switching during human supervision of multiple semi-autonomous robots in a dynamic environment, 2010
- [37] P. Benavidez et al., "Design of semi-autonomous robots for competitive robotics," World Automation Congress 2012, Puerto Vallarta, Mexico, 2012
- [38] BEKEY GA. On autonomous robots. The Knowledge Engineering Review. 1998
- [39] R. G. Simmons, "Structured control for autonomous robots," in IEEE Transactions on Robotics and Automation, vol. 10, no. 1, pp. 34-43, Feb. 1994

- [40] KNUDSON, Matt; TUMER, Kagan. Adaptive navigation for autonomous robots. Robotics and Autonomous Systems, 2011
- [41] A. F. Foka and P. E. Trahanias, "Predictive autonomous robot navigation," IEEE/RSJ International Conference on Intelligent Robots and Systems, Lausanne, Switzerland, 2002
- [42] WANDINGER, Ulla. Introduction to lidar. In: Lidar: range-resolved optical remote sensing of the atmosphere. New York, NY: Springer New York, 2005
- [43] JABOYEDOFF, Michel, et al. Use of LIDAR in landslide investigations: a review. Natural hazards, 2012
- [44] LI, Nanxi, et al. A progress review on solid-state LiDAR and nanophotonics-based LiDAR sensors. Laser & Photonics Reviews, 2022
- [45] FLEMING, William J. Overview of automotive sensors. IEEE sensors journal, 2001
- [46] BENET, Gines, et al. Using infrared sensors for distance measurement in mobile robots. Robotics and autonomous systems, 2002
- [47] ZAPPI, Piero; FARELLA, Elisabetta; BENINI, Luca. Tracking motion direction and distance with pyroelectric IR sensors. IEEE Sensors Journal, 2010
- [48] KIPP, Sebastian; MISTELE, Bodo; SCHMIDHALTER, Urs. The performance of active spectral reflectance sensors as influenced by measuring distance, device temperature and light intensity. Computers and Electronics in Agriculture, 2014
- [49] PHILLIPS-WREN, Gloria. AI tools in decision making support systems: a review. International Journal on Artificial Intelligence Tools, 2012
- [50] ARAUJO, Theo, et al. In AI we trust? Perceptions about automated decision-making by artificial intelligence. AI & society, 2020
- [51] RASTOGI, Charvi, et al. Deciding fast and slow: The role of cognitive biases in ai-assisted decision-making. Proceedings of the ACM on Human-Computer Interaction, 2022
- [52] YASIN, Jawad N., et al. Low-cost ultrasonic based object detection and collision avoidance method for autonomous robots. International Journal of Information Technology, 2021

- [53] BOLANOS, José M., et al. Object recognition for obstacle avoidance in mobile robots. In: Artificial Intelligence and Soft Computing–ICAISC 2006: 8th International Conference, Zakopane, Poland, June 25-29, 2006. Proceedings 8. Springer Berlin Heidelberg, 2006
- [54] SUGIURA, Hisashi, et al. Real-time collision avoidance with whole body motion control for humanoid robots. In: 2007
- [55] FLACCO, Fabrizio, et al. A depth space approach for evaluating distance to objects: with application to human-robot collision avoidance. Journal of Intelligent & Robotic Systems, 2015
- [56] CHIRIATTI, Giorgia, et al. Adaptive obstacle avoidance for a class of collaborative robots. Machines, 2021
- [57] BIRK, Andreas; KENN, Holger. A rescue robot control architecture ensuring safe semi-autonomous operation. In: RoboCup 2002
- [58] Sollenberger, R. (2005). Human-in-the-Loop Simulation Evaluating the Collocation of the User Request Evaluation Tool. U.S. Department of Transportation Federal Aviation Administration, 1. Retrieved July 19, 2010
- [59] MARCANO, Mauricio, et al. A review of shared control for automated vehicles: Theory and applications. IEEE Transactions on Human-Machine Systems, 2020
- [60] ASTROM, K. Johan. Adaptive feedback control. Proceedings of the IEEE, 1987
- [61] BENTLEY, J. P. Temperature sensor characteristics and measurement system design. Journal of Physics E: Scientific Instruments, 1984
- [62] UKIL, Abhisek; BRAENDLE, Hubert; KRIPPNER, Peter. Distributed temperature sensing: Review of technology and applications. IEEE Sensors Journal, 2011
- [63] KRUMMENACHER, P.; OGUEY, H. Smart temperature sensor in CMOS technology. Sensors and Actuators A: Physical, 1990
- [64] YUN, Huitaek, et al. Development of internal sound sensor using stethoscope and its applications for machine monitoring. Procedia Manufacturing, 2020
- [65] OLETIC, Dinko; ARSENALI, Bruno; BILAS, Vedran. Low-power wearable respiratory sound sensing. Sensors, 2014

- [66] KANG, Sungchan, et al. Directional sound sensor with consistent directivity and sensitivity in the audible range. *Journal of Microelectromechanical Systems*, 2021
- [67] SILBERMAN, Nathan; FERGUS, Rob. Indoor scene segmentation using a structured light sensor. In: 2011 IEEE international conference on computer vision workshops (ICCV workshops). IEEE, 2011
- [68] BAI, Ying-Wen; KU, Yi-Te. Automatic room light intensity detection and control using a microprocessor and light sensors. *IEEE Transactions on Consumer Electronics*, 2008
- [69] ZHMUD, V. A., et al. Application of ultrasonic sensor for measuring distances in robotics. In: *Journal of Physics: Conference Series*. IOP Publishing, 2018
- [70] HENNING, Bernd; RAUTENBERG, Jens. Process monitoring using ultrasonic sensor systems. *Ultrasonics*, 2006
- [71] GROSS, Jennifer. Interviewing Roomba: A posthuman study of humans and robot vacuum cleaners. *Explorations in Media Ecology*, 2020
- [72] LI, Meng, et al. Soft actuators for real-world applications. *Nature Reviews Materials*, 2022
- [73] CATTAFESTA III, Louis N.; SHEPLAK, Mark. Actuators for active flow control. *Annual Review of Fluid Mechanics*, 2011
- [74] HUBBARD, Neal B.; CULPEPPER, Martin L.; HOWELL, Larry L. Actuators for micropositioners and nanopositioners. 2006.
- [75] HENRIKSSON, Dan; CERVIN, Anton; ÅRZÉN, Karl-Erik. TrueTime: Simulation of control loops under shared computer resources. *IFAC Proceedings Volumes*, 2002
- [76] MEHMEDOVIĆ, Muharem. Identifikacija parametara sustava regulacije uzbude sinkronih strojeva. 1995
- [77] SMYCZYŃSKI, Paweł; STARZEC, Łukasz; GRANOSIK, Grzegorz. Autonomous drone control system for object tracking: Flexible system design with implementation example. In: 2017
- [78] YARLAGADDA, Ravi Teja. Future of robots, AI and automation in the United States. *IEJRD-International Multidisciplinary Journal*, 2015

- [79] SHI, Yuanming, et al. Communication-efficient edge AI: Algorithms and systems. IEEE Communications Surveys & Tutorials, 2020
- [80] GO, Hanyoung; KANG, Myunghwa; SUH, SeungBeum Chris. Machine learning of robots in tourism and hospitality: interactive technology acceptance model (iTAM)—cutting edge. Tourism review, 2020
- [81] LORNE, Frank T.; GOGIREDDY, Mahita Reddy. Digital social contracts with AI robots: some implications for Amazon. Com. In: European, Asian, Middle Eastern, North African Conference on Management & Information Systems. Cham: Springer International Publishing, 2021
- [82] DIANA, M.; MARESCAUX, JBJoS. Robotic surgery. Journal of British Surgery, 2015
- [83] MATTIOLI, Girolamo, et al. Da Vinci robotic surgery in a pediatric hospital. Journal of Laparoendoscopic & Advanced Surgical Techniques, 2017
- [84] MAURETTE, Michel. Mars rover autonomous navigation. Autonomous Robots, 2003
- [85] RANKIN, Arturo, et al. Driving curiosity: Mars rover mobility trends during the first seven years. In: 2020 IEEE Aerospace Conference. IEEE, 2020
- [86] AKI, J. N., et al. The Mars 2020 Engineering Cameras and microphone on the perseverance rover: A next-generation imaging system for Mars exploration. Space science reviews, 2020
- [87] NASO, Filippo, et al. Alpha-Gal detectors in xenotransplantation research: a word of caution. Xenotransplantation, 2012
- [88] GOLD, R. E., et al. Electron, proton, and alpha monitor on the advanced composition explorer spacecraft. The Advanced Composition Explorer Mission, 1998
- [89] CVOK, Marijan. Izrada i ispitivanje blastera za digitalni seizmograf. 1998
- [90] BUDDE, Matthias; BUSSE, Mathias; BEIGL, Michael. Investigating the use of commodity dust sensors for the embedded measurement of particulate matter. In: 2012
- [91] YU, Limin, et al. Review of research progress on soil moisture sensor technology. 2021
- [92] MARSHALL, Alan G.; HENDRICKSON, Christopher L. High-resolution mass spectrometers. Annu. Rev. Anal. Chem., 2008

- [93] MARCHANT, Gary E., et al. International governance of autonomous military robots. *Colum. Sci. & Tech. L. Rev.*, 2011
- [94] OH, Elizabeth E. Policing police robots. *UCLA L. Rev. Discourse*, 2016
- [95] YAMAUCHI, Brian M. PackBot: a versatile platform for military robotics. In: *Unmanned ground vehicle technology VI*. SPIE, 2004
- [96] YOUNES, Magdy. The case for using digital EEG analysis in clinical sleep medicine. *Sleep Science and Practice*, 2017
- [97] XINGYUAN, Wang; CHAO, Luo. Researches on chaos phenomenon of EEG dynamics model. *Applied Mathematics and Computation*, 2006
- [98] BESTHORN, Christoph, et al. EEG coherence in Alzheimer disease. *Electroencephalography and clinical neurophysiology*, 1994
- [99] GSCHWANDTNER, Ute, et al. EEG: a helpful tool in the prediction of psychosis. *European archives of psychiatry and clinical neuroscience*, 2009
- [100] IANOF, Jéssica Natuline; ANGHINAH, Renato. Traumatic brain injury: An EEG point of view. *Dementia & neuropsychologia*, 2017
- [101] CHARYA, U. Rajendra, et al. Automated EEG analysis of epilepsy: a review. *Knowledge-Based Systems*, 2013
- [102] CAMPBELL, Ian G. EEG recording and analysis for sleep research. *Current protocols in neuroscience*, 2009
- [103] ZHAO, Xiaoyun, et al. Classification of sleep apnea based on EEG sub-band signal characteristics. *Scientific Reports*, 2021
- [104] LIU, Derong; PANG, Zhongyu; LLOYD, Stephen R. A neural network method for detection of obstructive sleep apnea and narcolepsy based on pupil size and EEG. *IEEE Transactions on Neural Networks*, 2008
- [105] MICHEL, V., et al. Long-term EEG in adults: sleep-deprived EEG (SDE), ambulatory EEG (Amb-EEG) and long-term video-EEG recording (LTVÉR). *Neurophysiologie Clinique/Clinical Neurophysiology*, 2015

- [106] BELL, Martha Ann; CUEVAS, Kimberly. Using EEG to study cognitive development: Issues and practices. *Journal of cognition and development*, 2012
- [107] WORSLEY, Keith J., et al. A general statistical analysis for fMRI data. *Neuroimage*, 2002
- [108] BASU, Sandip, et al. Fundamentals of PET and PET/CT imaging. *Annals of the New York Academy of Sciences*, 2011
- [109] PIJN, Jan Pieter, et al. Chaos or noise in EEG signals; dependence on state and brain site. *Electroencephalography and clinical Neurophysiology*, 1991
- [110] SANEI, Saeid; CHAMBERS, Jonathon A. EEG signal processing. John Wiley & Sons, 2013
- [111] TAUSSIG, D.; MONTAVONT, A.; ISNARD, J. Invasive EEG explorations. *Neurophysiologie Clinique/Clinical Neurophysiology*, 2015
- [112] NAM, Chang S. Brain–computer interface (BCI) and ergonomics. *Ergonomics*, 2012
- [113] ELSTOB, Daniel; SECCO, Emanuele Lindo. A low cost EEG based BCI prosthetic using motor imagery. arXiv preprint arXiv:1603.02869, 2016
- [114] ROBINSON, Neethu, et al. Emerging trends in BCI-robotics for motor control and rehabilitation. *Current Opinion in Biomedical Engineering*, 2021
- [115] MARSHALL, David, et al. Games, gameplay, and BCI: the state of the art. *IEEE Transactions on Computational Intelligence and AI in Games*, 2013
- [116] ZAGHLOUL, Zaghoul Saad; BAYOUMI, Magdy. Adaptive neural matching online spike sorting VLSI chip design for wireless BCI implants. In: 2015
- [117] ARMOCIDA, Daniele; GARBOSSA, Diego; COFANO, Fabio. Ethical concerns and scientific communication on neuralink device. *Neurosurgical Review*, 2024
- [118] HU, Li; ZHANG, Zhiguo (ed.). EEG signal processing and feature extraction. 2019
- [119] DIENEL, Gerald A. Fueling and imaging brain activation. *ASN neuro*, 2012
- [120] TAUSSIG, D.; MONTAVONT, A.; ISNARD, J. Invasive EEG explorations. *Neurophysiologie Clinique/Clinical Neurophysiology*, 2015
- [121] MILLÁN, José del R.; CARMENA, Jose. Invasive or noninvasive: understanding brain-machine interface technology. *IEEE Engineering in Medicine and Biology Magazine*, 2010

- [122] REDLER, Rachel L.; DOKHOLYAN, Nikolay V. The complex molecular biology of amyotrophic lateral sclerosis (ALS). Progress in molecular biology and translational science, 2012
- [123] HALAN, Taras, et al. Locked-In syndrome: a systematic review of long-term management and prognosis. Cureus, 2021
- [124] BABA, Samiya Majid; BALA, Indu. Smart communication interpreter for mute and deaf people. Asian Journal of Electrical Sciences, 2022
- [125] XU, Jiahui; ZHONG, Baichang. Review on portable EEG technology in educational research. Computers in Human Behavior, 2018
- [126] ANTONENKO, Pavlo, et al. Using electroencephalography to measure cognitive load. Educational psychology review, 2010
- [127] HARMONY, Thalia, et al. Correlation between EEG spectral parameters and an educational evaluation. International Journal of Neuroscience, 1990
- [128] DIAZ-PIEDRA, Carolina; SEBASTIÁN, María Victoria; DI STASI, Leandro L. EEG theta power activity reflects workload among army combat drivers: an experimental study. Brain sciences, 2020
- [129] LIU, Ye, et al. A boosting-based spatial-spectral model for stroke patients' EEG analysis in rehabilitation training. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2015
- [130] Sigal Samuel, 18.04.2024., <https://www.vox.com/future-perfect/24078512/brain-tech-privacy-rights-neurorights-colorado-yuste>, 30.08.2024.
- [131] KAPPENMAN, Emily S.; LUCK, Steven J. of brainwave recordings. The Oxford handbook of event-related potential components, 2011
- [132] KOUDELKOVÁ, Zuzana; STRMISKA, Martin. Introduction to the identification of brain waves based on their frequency. In: MATEC Web of Conferences. EDP Sciences, 2018
- [133] FROHLICH, Joel; TOKER, Daniel; MONTI, Martin M. Consciousness among delta waves: a paradox?. Brain, 2021

- [134] SAXBY, Ellen; PENISTON, Eugene G. Alpha-theta brainwave neurofeedback training: An effective treatment for male and female alcoholics with depressive symptoms. *Journal of clinical psychology*, 1995
- [135] MARSHALL, Marie Sage; BENTLER, Peter M. The effects of deep physical relaxation and low-frequency-alpha brainwaves on alpha subjective reports. *Psychophysiology*, 1976
- [136] USTMAN, Robert E.; BOSWELL, Reed S.; PORTER, Paul B. Beta brain waves as an index of alertness. *Science*, 1962
- [137] JIA, Xiaoxuan; KOHN, Adam. Gamma rhythms in the brain. *PLoS biology*, 2011
- [138] FENG, Guosheng. Effects of attention and concentration on performance and training methods in athletes. *Revista multidisciplinar de las Ciencias del Deporte*, 2024
- [139] KIM, Min-Kyung. Brainwave and Emotional Responses of Male and Females to Munsell's Five Primary Colors. *Asian Journal of Beauty and Cosmetology*, 2024
- [140] GUO, Yitong, et al. Energy and synchronization between two neurons with nonlinear coupling. *Cognitive Neurodynamics*, 2024

Slike

Slika 4.1 Moždani valovi	18
Slika 5.1 Dijagram protoka podataka.....	23
Slika 5.2 Unakrsna validacija Naivnog Bayesa	30
Slika 5.3 Matrica Zabune Naivnog Bayesa.....	32
Slika 5.4 Formula za računanje koeficijenta točnosti	33
Slika 5.5 Uvršteni parametri za računanje točnosti Naivnog Bayesa	33
Slika 5.6 Formula za računanje koeficijenta preciznosti	33
Slika 5.7 Uvršteni parametri za računanje preciznosti Naivnog Bayesa	33
Slika 5.8 Formula za računanje koeficijenta osjetljivosti	34
Slika 5.9 Uvršteni parametri za računanje osjetljivosti Naivnog Bayesa	34
Slika 5.10 Formula za računanje vrijednosti F1-Rezultat.....	34
Slika 5.11 Uvršteni parametri za računanje F1-Rezultata Naivnog Bayesa	34
Slika 5.12 Krivulja učenja Naivnog Bayesa	36
Slika 5.13 Krivulja učenja Stabla Odluke.....	38
Slika 5.14 Krivulja učenja Stabla Odluke na dubini 3	40
Slika 5.15 Krivulja validacije modela Stabla Odluke po dubini.....	42
Slika 5.16 Matrica Zabune Stabla Odluke	44
Slika 5.17 Uvršteni parametri za računanje točnosti Stabla Odluke.....	44
Slika 5.18 Uvršteni parametri za računanje preciznosti Stabla Odluke.....	45
Slika 5.19 Uvršteni parametri za računanje osjetljivosti od modela Stabla Odluke	45
Slika 5.20 Uvršteni parametri za računanje F1-Rezultata od modela Stabla Odluke	45
Slika 5.21 Stablo odluke	47
Slika 5.22 Unakrsna validacija modela Slučajne Šume.....	49
Slika 5.23 Matrica zabune za model Slučajne Šume	51
Slika 5.24 Uvršteni parametri za računanje točnosti od modela Slučajne Šume.....	51
Slika 5.25 Uvršteni parametri za računanje preciznosti od modela Slučajne Šume	52
Slika 5.26 Uvršteni parametri za računanje osjetljivosti od modela Slučajne Šume.....	52
Slika 5.27 Uvršteni parametri za računanje F1-Rezultata od modela Slučajne Šume.....	52
Slika 5.28 Graf utjecaja podataka na odluku modela Slučajne Šume.....	53