

Klasifikacija geometrijskih likova koristeći EEG podatke

Šajina, David

Undergraduate thesis / Završni rad

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:137:497085>

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

Download date / Datum preuzimanja: **2024-09-09**



Repository / Repozitorij:

[Digital Repository Juraj Dobrila University of Pula](#)



Sveučilište Jurja Dobrile u Puli
Fakultet informatike u Puli

David Šajina

Klasifikacija geometrijskih likova koristeći EEG podatke

Završni rad

Pula, 2022.

Sveučilište Jurja Dobrile u Puli
Fakultet informatike u Puli

David Šajina

Klasifikacija geometrijskih likova koristeći EEG podatke

Završni rad

Ime Prezime studenta/studentice, JMBAG: David Šajina, 0303088268

Studijski smjer: preddiplomski sveučilišni studij informatika

Znanstveno područje: Društvene znanosti

Znanstveno polje: Informacijske i komunikacijske znanosti

Znanstvena grana: Informacijski sustavi i informatologija

Mentor: doc. dr. sc. Nikola Tanković

Pula, rujan 2022.



IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani David Šajina, kandidat za prvostupnika informatike ovime izjavljujem da je ovaj Završni rad rezultat isključivo mogega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Završnog rada nije napisan na nedozvoljeni način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

David Šajina

U Puli, rujan 2022.



IZJAVA O KORIŠTENJU AUTORSKOG DJELA

Ja, David Šajina dajem odobrenje Sveučilištu Jurja Dobrile u Puli, kao nositelju prava iskorištavanja, da moj Završni rad pod nazivom Klasifikacija geometrijskih likova koristeći EEG podatke

koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.

Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, rujan 2022.

Potpis

Šajina

Sadržaj

| | | |
|-----|-------------------------------------|----|
| 1 | Uvod | 1 |
| 2 | Srodna istraživanja..... | 3 |
| 3 | Metodologija..... | 4 |
| 3.1 | Materijali..... | 4 |
| 3.2 | Podaci | 5 |
| 3.3 | Konvolucijske neuronske mreže | 7 |
| 3.4 | Proces treniranja..... | 9 |
| 3.5 | Model..... | 10 |
| 3.6 | Struktura projekta..... | 12 |
| 4 | Rezultati i diskusija..... | 14 |
| 5 | Zaključak | 16 |
| | Literatura | 17 |
| | Sažetak i ključne riječi..... | 19 |

1 Uvod

Elektroencefalografija (eng. *Electroencephalography* - EEG) mjeri slabe elektromagnetske signale koje stvara aktivnost neurona u mozgu (Gramfort i ostali, 2013). EEG podaci se često prikazuju kao vremenska serija ili kao protok voltaže. Kako bi se bolje prikazala aktivnost mozga, bolje koristiti više EEG mjerenja signala koja su smještena svuda oko površine mozga. Zbog svoje vremenske rezolucije u području milisekundi kao i zbog svoje neinvazivnosti, prenosivosti i relativno niske cijene, elektroencefalografija je popularno i široko korišteno mjerenje tehnika za proučavanje dinamike mozga i interakcije kod ljudi (Haufe i ostali, 2012). Strojno učenje (eng. *machine learning*) odnosi se na podskup umjetne inteligencije (AI) gdje se programi stvaraju bez korištenja programera koji ručno kreiraju program (Khanzode, Sarode, 2020). Umjesto da sami napišu kompletan program, programeri daju AI "uzorak" za prepoznavanje i učenje, a zatim AI-u daju velike količine podataka da ih pregleda i proučava. Umjesto posebnih pravila kojih se treba pridržavati, AI traži uzorke unutar podataka i koristi ih za poboljšanje svojih već postojećih funkcija.

Brain-Computer Interfaces (BCI) su sustavi koji omogućuju stvaranje izravnog komunikacijskog kanala između mozga i vanjskih elektroničkih uređaja bez potrebe za korištenjem perifernog živčanog sustava (Wolpaw i ostali, 2000.). Open-source brain-computer interface (OpenBCI) pristupačan je biosenzorski sustav koji može mjeriti električnu aktivnost ljudskog tijela poput aktivnosti mozga (EEG), skeletnih mišića (EMG) i srca (EKG). Korišten je model OpenBCI Cyton. Cyton omogućuje prikupljanje EEG podataka iz 16 različitih kanala. Uređaj na sebi ima 16 elektroda koje dohvaćaju signale mozga koje pretvara u podatke.

Neuralne mreže (eng. *neural network*) sastoji se od ulaznog sloja neurona (ili čvorova, jedinica), jedan ili dva (ili čak tri) skrivena sloja neurona i završni sloj izlaznih neurona (Wang, 2003). Neuralne mreže su sredstvo za strojno učenje u kojem računalo uči obavljati neki zadatak analizirajući primjera za treniranje tj. nastoji prepoznati odnose u skupu podataka kroz proces koji oponaša način na koji funkcionira ljudski mozak. Neuralne mreže imaju očite značajke uključujući visoke brzine obrade i sposobnost učenja rješenja za problem iz niza primjera (Kumar i Thakur, 2012). Neuralne mreže rade na principu ljudskog mozga, umjetna neuronska mreža (eng. *artificial neural network* - ANN) sastoji se od jednostavnih umjetnih neurona, a svaka jedinica je povezana s drugom jedinicom preko težinskih spojeva. Neuroni izračunavaju izvagani zbroj ulaznih podataka i saznaju izlaz koristeći funkciju aktivacije (Zayegh i Bassam, 2018.). Neuralne mreže se koriste za implementaciju različitih faza obradnih sustava temeljenih na učenju algoritama, kontrolirajući njihove težine (eng. *weights*) i pristranosti (eng. *bias*) (Zayegh i Bassam, 2018.). Težine predstavljaju jačinu veze između

jedinica. Težine blizu nule znači da promjena ulaza neće promijeniti izlaz. Negativne težine znače da će povećanje ulaza smanjiti izlaz. Težina odlučuje koliko će ulaz imati utjecaja na izlaz. Neuralne mreže se također sastoje od aktivacijskih funkcija, a one služe za proizvodnju izlaza neurona. Postoji nekoliko različitih tipa aktivacijskih funkcija. Linearna funkcija je funkcija gdje je izlaz neurona proporcionalan ulazu. Funkcija praga (koraka) radi na način kada je vrijednost umnoška zbroja pozitivna, rezultat aktivacijske funkcije će vratiti 1, a kada je vrijednost umnoška zbroja manja od 0, rezultat aktivacijske funkcije je nula. Sigmoid funkcija nam garantira da će izlaz uvijek biti između 0 i 1. Tanh aktivacijska funkcija osigurava, što je veći ulaz tj. što je pozitivniji to će izlazna vrijednost biti bliža 1,0, kada je ulaz negativnija ili manja vrijednost to će izlaz biti bliži -1,0.

Ovaj rad fokusirat će se na klasifikaciju tri geometrijska oblika koristeći EEG podatke, model je personaliziran za jednog ispitanika. Za treniranje modela koristit će se konvolucijska neuralna mreža pri čemu će se napraviti obrada nad skupom podataka kako bi oni bili kompatibilni. Cilj ovog projekta je istražiti i odgovoriti u kojoj mjeri se mogu klasificirati geometrijski oblici koristeći EEG podatke. Također cilj je istražiti dali su EEG podaci relevantni bez obzira na vremenski period, u tu svrhu snimljeni su podaci za prve dvije sesije, treća sesija je snimljena mjesec dana kasnije, dok su ostale tri snimljene 4 mjeseca kasnije.

2 Srodna istraživanja

Istraživački rad pod nazivom „Brain-Computer Interface Based on Generation of Visual Images“ (Borbov i ostali, 2011) proučava mogućnost klasifikacije dva objekta (kuća i ljudsko lice) i stanje opuštanja. Ispitana je grupa od sedam ispitanika te je najveća postignuta klasifikacijska točnost iznosila je 68%. U radu se opisuje kako je 8 elektroda optimalna konfiguracija za klasifikaciju.

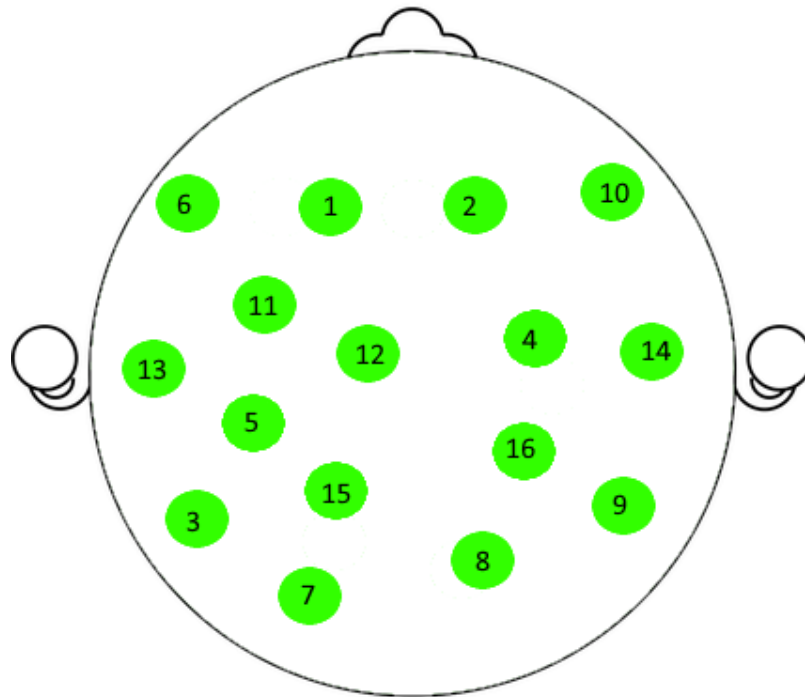
Istraživački rad „Classification of imagined geometric shapes using EEG signals and convolutional neural networks“ (Llorella i ostali, 2021.) istražuje klasifikaciju sedam geometrijskih objekta. Srednja vrijednost točnosti klasifikacije sedam geometrijskih objekta iznosi 35% dok klasifikacija geometrijske linije i paralelograma iznosi 70%. Uređaj koji je korišten u navedenom radu ima samo 8 kanala. Skup podataka (eng. *dataset*) je prikupljen tako da se je prikazala slika geometrijskog tijela na par sekundi te su tada ispitanici zamišljali prikazani geometrijski lik. Svaki model je personaliziran tj. napravljen točno za tog ispitanika. Istraživački rad „Classification of primitive shapes using brain-computer interfaces“ (Esfahani i Sundararajan, 2012) klasificira pet geometrijskih oblika (kocka, sfera, cilindar, piramida i stožac) s točnosti od 36%- 54% tj. srednjom točnosti od 44,60% pri čemu je korišten uređaj s 14 kanala.

Istraživački rad „Classification of Visual Perception and Imagery based EEG Signals Using Convolutional Neural Networks“ (Bang i ostali, 2020) koristi uređaj s 32 kanala pri čemu se radi o klasifikaciji šest geometrijskih oblika. Korištenjem konvolucijskih mreža dobiven je rezultat od 32,56% klasifikacijske točnosti. „Brain2Object: Printing Your Mind from Brain Signals with Spatial Correlation Embedding“ (Zhang i ostali, 2020) također koristi konvolucijske mreže pri čemu su klasificirana četiri imaginarna oblika. Pri korištenju lokalne baze podataka rezultat točnosti iznosi 75,23% dok je rezultat od 92,58% dobiven koristeći javnu bazu podataka.


3 Metodologija

3.1 Materijali


U ovom radu korišten je uređaj OpenBCI Cyton + Daisy (Slika 3) koji su razvili Joel Murphy i Conor Russomanno. Uređaj OpenBCI Cyton + Daisy koji je korišten za snimanje EEG signala se sastoji 16 kanala. Uređaj radi na frekvencijama i do 250Hz, također ima bežično sučelje koje radi na 2.4GHz. Korišteno je 16 suhih elektroda koje su posložene kao što je prikazano na Slici 1. Snimanje EEG signala bilo je u kontroliranim uvjetima pri čemu nije bilo prodora buke, jake svjetlosti ili ostalih smetnji. Pri prikupljanju podataka korištena su 3 geometrijska oblika kao što je prikazano na Slici 2.



Slika 1. Prikaz pozicija korištenih elektroda



Slika 2. Prikaz geometrijskih oblika korištenih pri snimanju EEG signala




Slika 3. Prikaz OpenBCI kacige i sesije snimanja podataka

3.2 Podaci


Podaci su snimljeni putem OpenBCI GUI-a s kojega su preko LSL-a (eng. Lab streaming layer) direktno spremeni. Podaci su se prikupljali tako da se je fokusiralo na jedan objekt u sesijama po dvije minute (Slika 3). Najprije je napravljena testna sesija u kojoj se je ispitanik što duže fokusirao na određeni geometrijski lik (ti podaci nisu spremljeni) pri čemu je donesen zaključak da je optimalno vrijeme koncentracije ispitanika 120 sekunda tj. dvije minute. Za svaki geometrijski oblik skupljalo se podatke po 6 sesija što znači da skup podataka za treniranje ima 178200 opservacija

tj. 59400 opservacija po geometrijskom obliku. Nakon što su snimljene prve dvije sesije, treća je snimljena mjesec dana kasnije, dok su ostale tri snimljene 4 mjeseca kasnije.

Prikupljeni podaci limitirani su do 60Hz, a broj mjerenja u sekundi iznosio je 90. Snimani podaci prikupljeni su bez vanjskih smetnji (buke, izloženosti velikoj svjetlosti i sl.). Pri snimanju podataka zaslon uređaja na kojem su bili prikazani geometrijski oblici bio je na udaljenosti od 60 cm. Tijekom snimanja podataka konstantno se gleda i misli na prikazani objekt. Ako je ispitanik primijetio manjak koncentracije tj. da počinje gubiti fokus, taj skup podataka je izbrisan. OpenBCI GUI ima prikaz podataka uživo pa je prema tome vidljivo ako je ispitanik koncentriran (Slika 4). Slika 5 prikazuje signale mozga pri normalnom razgovoru s ispitanikom. Uočavamo kako pri fokusiranju na geometrijski oblik iščitavanja kanala su slična, npr. na frekvenciji od 20Hz uočavamo kako su amplitude oko maksimalno 0,7 uV (Slika 4.), a na Slici 5 vidljivo je kako na 20Hz amplitude su maksimalno na 5 uV. Na 50Hz imamo amplitude visoke vrijednosti koje su uzrokovane zbog dalekovoda.



Slika 4. Prikaz signala mozga pri fokusiranju na geometrijski oblik

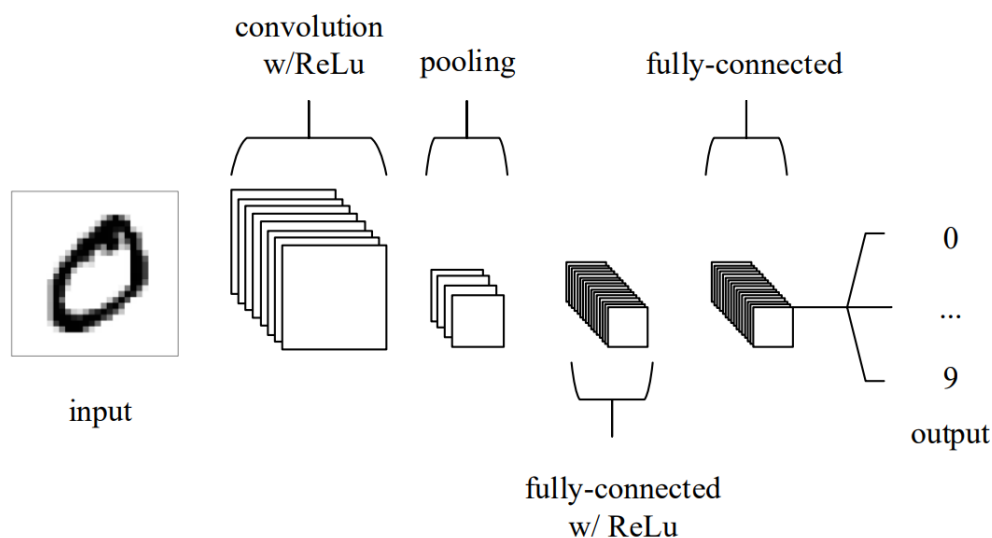


Slika 5. Prikaz signala mozga pri normalnom razgovoru

3.3 Konvolucijske neuronske mreže

Konvolucijske neuronske mreže (eng. *Convolutional neural networks* - CNN) vrsta su neuronskih mreža koje imaju ukomponirane konvolucijske slojeve. CNN je bio najkorišteniji za klasifikaciju i obradu slika, međutim CNN se također može primijeniti na klasifikaciju EEG signala (Schirrmester i ostali, 2017.). Konvolucija radi tako da pretvara sve piksele slike u jednu vrijednost te je konačni izlaz konvolucijskog sloja vektor

CNN obično ima tri sloja: konvolucijski sloj (eng. *convolutional layer*), skupni sloj (eng. *pooling layer*) i potpuno povezani sloj (eng. *fully connected layer*). Kao što naziv implicira, konvolucijski sloj diktira kako će CNN operirati. Parametri slojeva fokusirani su oko upotrebe kernela (O'Shea i Nash, 2015). Na Slici 6 prikazana je jednostavna CNN arhitektura koju su predložili O'Shea i Nash.



Slika 6. Prikaz jednostavne CNN arhitekture složene od 5 slojeva (O'Shea i Nash, 2015).


Konvolucijski sloj je najosnovniji, ali u isto vrijeme najbitniji sloj u CNN-u. Konvolucijski sloj radi na principu tako da množi matricu piksela koja je generirana za neku sliku ili objekt kako bi se napravila aktivacijska mapa za danu sliku. Aktivacijska mapa nam omogućuje da vidimo koje su dijelovi na slici relevantni za klasu na koju se odnosi (Ajit i ostali, 2020). Aktivacijske mape pohranjuju sva obilježja koja se ističu na slici ili objektu pri čemu se također smanjuje veličina podataka za obradu. Konvoluiran model je također obučen s povratnim širenjem (eng. *backpropagation*) kako bi se utvrdila minimalna greška u svakom sloju tj. izračunava gradijent funkcije gubitaka s obzirom na težine mreže.

Skupni sloj igra važnu ulogu u CNN-ovima jer je uglavnom odgovoran za nepromjenjivost podataka na varijacije. Skupni sloj može se dobiti operacijom udruživanja koja obično sadrži dva koraka. Prvo se skenira mapu značajki i prikuplja odgovore unutar svake lokalne regije. Drugi korak je operacija smanjenog uzorkovanja (eng. *down sampling*) koja zadržava samo dio agregiranih podataka svakog kanala. Operacija smanjenog uzorkovanja može smanjiti veličina kanala, a time i smanjuje računalno opterećenje (Graham, 2014).

Potpuno povezani sloj je FNN (eng. *feedforward neural network*) neuronska mreža pri čemu veze između čvorova ne formiraju ciklus. Potpuno povezani slojevi čine posljednjih nekoliko slojeva u mreži. Ulaz u potpuno povezani sloj je izlaz iz konačnog udruživanja ili konvolucijskog sloja, koji se spljošti (eng. *flatten*) i zatim unosi u potpuno povezani sloj. U jednostavnom CNN-u modela, značajke generirane završnim konvolucijskim slojem odgovaraju na dio ulazne slike jer njeno receptivno polje ne pokriva cijelu prostornu dimenziju slike (Basha i ostali, 2020)

3.4 Proces treniranja

Do modela korištenog u ovom radi došlo se je na način pokušaja i pogreška (eng. trial and error). Na početku predložen je model koji koristi 1D konvolucijski sloj međutim zbog lošijih rezultata taj je model odbačen. Nakon toga postavljen je početni model koji je koristio 2D konvolucijske slojeve. Početni model se sastojao od tri uzastopna Conv2D sloja, Flatten sloja i dva Dense sloja, te su odmah primijećeni bolji. Nakon daljnjega proučavanja, taj model se je nastavio razvijati sve dok nije došao do finalne strukture kao što je prikazano na Slici 8. Na početku su podaci bili ručno odijeljeni u skup podataka za treniranje, skup podataka za validaciju i skup podataka za test modela, pri čemu je srednja vrijednost rezultata evaluacije točnosti modela s testnim podacima bila 37,50% što nije bila dovoljno prihvatljiva točnost. Skup podataka za treniranje služi kako bi model učio na njima. Skup podataka za validaciju se ne koristi za samo treniranje modela, već za evaluaciju točnosti ažuriranih parametara modela nakon epohe, u svrhu osiguravanja da model konvergira u pravom smjeru. Skup podataka za test modela služi nam kako bi napravili evaluaciju točnosti krajnjeg modela nad podacima koje model nikad nije vidio. Treba napomenuti da kako bi se odgovorilo na pitanje relevantnosti EEG podataka kroz vremenski period, svi podaci su postavljeni u jedan direktorij. Pri pokretanju treniranja, 30% podataka pripada skupu za test modela, te je 70% skupa podataka pripada skupu za treniranje modela, od kojih je daljnje uzeto 20% za validaciju. Na Slici 7 prikazan je dijagram toka koji prikazuje cijeli proces treniranja i evaluacije. Dijagram je napravljen po uzoru na istraživački rad „Classification of imagined geometric shapes using EEG signals and convolutional neural networks“ (Llorella i ostali, 2021.).



Slika 7. Prikaz procesa treniranja i evaluacije modela

3.5 Model

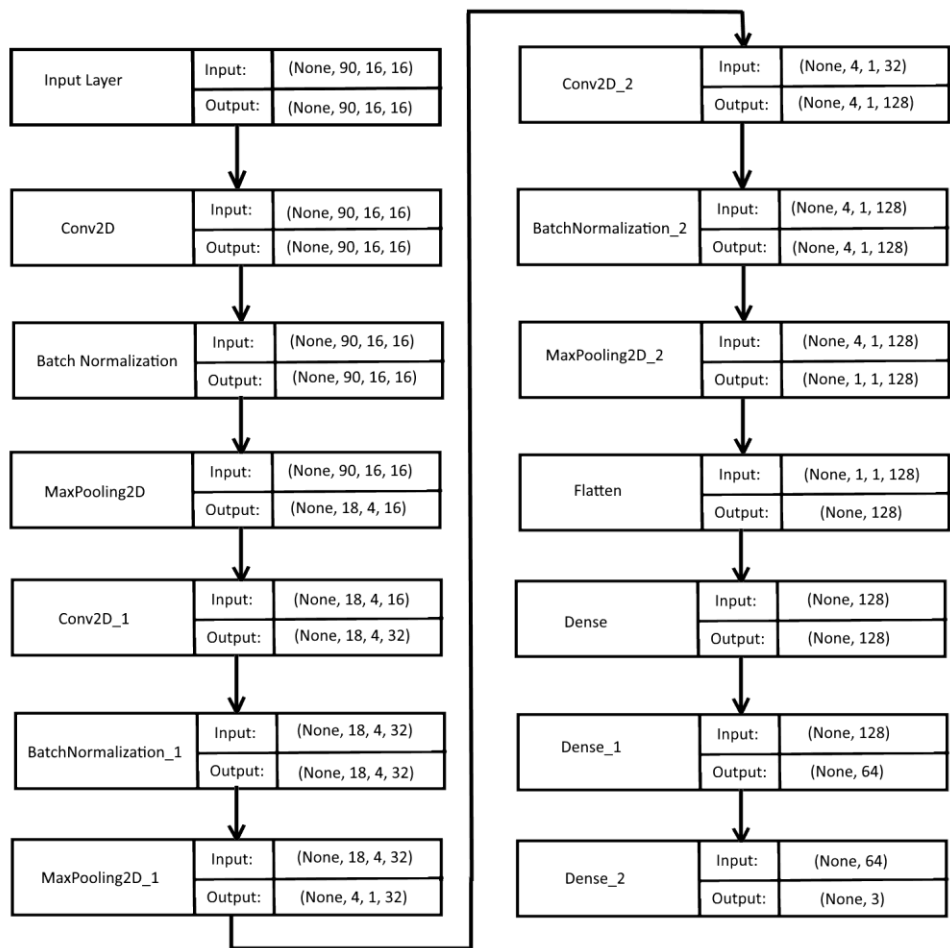
U radu je korišten je 2D konvolucijski sloj, napravila se je obrada nad podacima kako bi bila kompatibilna sa Conv2D slojevima pri čemu se je ulaz u model bio jedna sekunda snimanih EEG podataka tj. 90 mjerenja iz 16 kanala do 60Hz. Stopa učenja je postavljena na 0,007 pri čemu je veličina serije (eng. *batch size*) postavljena je na 32.

Struktura CNN mreže korištena u radu sastoji se od Conv2D slojeva, slojeva za normalizaciju serije, sloja maksimalnog udruživanja, flatten sloja i gustog sloja kao što je prikazano na Slici 8.

Zbog velike varijacije podataka također je korištena normalizacija serije (eng. *batch normalization*). Prije uvođenja normalizacije serije, vrijeme za osposobljavanje mreže za konvergenciju značajno je ovisilo o pažljivoj inicijalizaciji hiperparametara (npr. početne vrijednosti težine) i o korištenju malih stopa učenja, što je produžilo vrijeme obuke (Garbin i ostali, 2020). Normalizacija serije značajno smanjuje vrijeme treninga tako da normalizira svaki unos svakog sloja u mreži, a ne samo ulazni sloj. Normalizacija serije se koristi kako bi srednja vrijednost izlaza bila blizu 0 i izlazna standardna devijacija blizu 1 te s time povećava točnost. Način na koji funkcionira normalizacija serije je tako da podešavanjem vrijednosti jedinica za svaku seriju i činjenica da se serije stvaraju nasumično tijekom obuke, rezultira većim šumom tijekom procesa treninga. Konkretno, normalizacija serije prvo izračunava srednju vrijednost i vrijednost varijance za svaki kanal svoje ulazne karte karakteristika kroz vrijednosti preko mini serije; tada izvodi a normalizacija s faktorom skaliranja i faktorom pomaka (Jung i ostali, 2019)

Također korišten je sloj maksimalnog udruživanja (eng. *Max pooling*) kako bi pomoglo s problemom pretjeranog ugađanja (eng. *overfitting*) i kako bi se smanjio broj parametara za treniranje visoko u hijerarhiji obrade tj. izdvojili bolji podaci te to pojednostavljuje kompletnu složenost modela. Maksimalno udruživanje pomaže u izdvajanju značajki niske razine kao što su rubovi, točke i sl. Izlaz sloja maksimalnog udruživanja dan je maksimalnom aktivacijom preko područja koja se ne preklapaju. Maksimalno udruživanje smanjuje uzorkovanje (eng. *downsampling*) ulaznih objekta. Maksimalno udruživanje dovodi do brže stope konvergencije te se obično koristi nakon konvolucijskog sloja što je na kraju primijenjeno i u modelu koji je korišten za izradu ovog rada (Slika 8). Maksimalno udruživanje omogućuje međusobno pomicanje značajki što rezultira robusnim podudaranjem značajki čak i uz prisutnost malih izobličenja. Međutim, treba biti oprezan jer maksimalno udruživanje može oduzeti previše informacija, što rezultira lošijim rezultatima.

Korišten je i sloj flatten kojemu je zadatak poravnati izlaz tj. pretvoriti višedimenzionalni izlaz u linearnim kako bi bio spreman za gusti (eng. *dense*) sloj. Gusti sloj je duboko povezan, što znači da svaki neuron u gustom sloju prima ulaz od svih neurona svog prethodnog sloja te se ustvari koristi za promjenu dimenzija vektora.



Slika 8. Prikaz strukture CNN mreže korištene u radu

3.6 Struktura projekta

Struktura samog projekta je vrlo jednostavna te je cijeli izvorni kod kasnije naveden u sažetku ovog rada. Datoteka „data.py“ služi kako bismo snimili EEG podatke. Za rad te datoteke mora biti instaliran i otvoren OpenBCI GUI pri čemu opcija Networking mora biti postavljena na LSL. Prije pokretanja sam datoteke, treba izmijeniti varijablu „OBJECT“ u geometrijski oblik za koji se namjerava snimati skup podataka. Kada se pokreće datoteka „data.py“ ispitanik već mora biti u smirenom stanju i u kontroliranim uvjetima (bez buke, jake svjetlosti i sl.). Nakon pokretanja programa, treba proći još 10 sekundi prije nego što program počinje snimati podatke, kako bi se dalo dodatno vrijeme ispitaniku da se fokusira. Nakon dvije minute datoteka se automatski sprema u zadani direktorij.

Datoteka „Conv2Dtraining.py“ sadrži obradu podataka, treniranje i evaluaciju modela. U funkciji „create_data(starting_dir='alldata')“ se prema nazivu učitava skup podataka iz zadanog direktorija. Nakon toga dolazimo do obrade samih podataka za ulaz u model pri

čemu se modelu za ulaz daje 90 opservacija tj. po jedna sekunda snimljenih podataka. Podaci su podijeljeni tako da je 70% podataka opredijeljeno za treniranje i 30% podataka za test, tj. evaluaciju točnosti modela. Nakon svake epohe model se sprema i evaluira.

4 Rezultati i diskusija

Korišteni skup podataka EEG signala se sastoji od tri geometrijska oblika. Evaluacija točnosti modela iznosila je 59,76% pri čemu treba uzeti u obzir da je bilo deset potpunih prolaza skupa podataka za obuku kroz algoritam.

Spomenuto je kako su se podaci snimali kroz par mjeseci te je iz tog razloga napravljena analiza kako bi se utvrdilo dolazi li do mijenjanja podataka ovisno o vremenskom razmaku snimanja podataka tj. dolazi li do boljih rezultata. Nakon što su snimljene prve dvije sesije, treća je snimljena mjesec dana kasnije, dok su ostale tri snimljene 4 mjeseca kasnije.

Iz skupa podataka obrisani su podaci koji su bili snimani u zadnjem mjesecu (zadnje tri sesije) te dolazi do vrlo sličnih rezultata pri čemu je srednja vrijednost evaluacije točnosti modela iznosila 44,81%, zatim su ti podaci vraćeni u skup i obrisani podaci iz prve tri sesije, tj. iz prva dva mjeseca snimanja podataka. Opet dolazi do vrlo sličnih rezultata pri čemu je srednja vrijednost evaluacije točnosti modela iznosila 43,70%. Zaključuje se da su srednje vrijednosti evaluacije modela ne variraju previše (Tablica 1) pri čemu se dokazuje da su podaci jednako relevantni iako su snimani u vremenskom rasponu od 4 mjeseca.

| | Srednja vrijednost točnosti evaluacije modela |
|--|---|
| Skup podataka prve tri sesije (snimano 3.4.2022. i 10.5.2022.) | 43,70% |
| Skup podataka zadnje tri sesije (snimane 9.9.2022.) | 44,81% |
| Skup podataka svih sesija | 48,91% |

Tablica 1. Prikaz srednjih vrijednosti evaluacije modela

Prikazani rezultati klasifikacije tri geometrijska oblika koristeći EEG podatke pokazuju na točnost evaluacije modela od 59,76% što je odličan rezultat te to znači da je moguće klasificirati geometrijske oblike pomoću CNN modela. Jasno je kako pomoću EEG podatka i klasifikacijom oblika možemo dobiti odlične rezultate ali treba uzeti u obzir kako ti podaci moraju biti čisti, bez interferencija i bez vanjskih smetnji.

Također potrebno je napomenuti kako su podaci prikupljeni na samo jednom ispitaniku te ostavlja dosta prostora za buduće radove koji bi se mogli temeljiti na univerzalnom modelu.

5 Zaključak

U ovom istraživanju provedeno je ispitivanje klasifikacije geometrijskih oblika s EEG podacim. U istraživanju snimljeni su podaci putem uređaja OpenBCI Cyton + Daisy te preko softvera OpenBCI GUI. Podatke su izvučeni putem LSL-a i spremljeni. Podaci su snimani tako da je ispitanik gledao i mislio na objekt koji je bio prikazan na ekranu. Za svako geometrijsko tijelo skupljalo se podatke po 6 sesija što znači da skup podataka za treniranje ima 178200 opservacija tj. 59400 opservacija po geometrijskom obliku.

Podaci su bili snimani samo do 60Hz iako OpenBCI nudi mogućnosti za snimanje do čak 250Hz. Kako bi podaci bili što točniji prilikom snimanja podataka nije bilo prodora buke, velike izloženosti svjetlosti i sl. Korišten je CNN model zbog svoje uspješnosti pri treniranju slika, te je zbog toga također trebalo prilagoditi podatke kako bi bili kompatibilni s ulazom u model. Nakon obrade nad podacima, ulaz u model bio je jedna sekunda snimanih podataka tj. 90 mjerenja iz 16 kanala.

U modelu su korišteni slojevi: Conv2D, BatchNormalization, MaxPooling2D, Flatten i Dense. Stopa učenja je postavljena na 0,007 pri čemu je veličina serije (eng. *batch size*) postavljena je na 32.

Uspješno je istreniran model koji dokazuje da klasifikacijom geometrijskih tijela pomoću EEG podataka, koristeći konvolucijske neuralne mreže možemo dobiti dobre rezultate, međutim treba uzeti u obzir da se je radilo o jednom ispitaniku. Dobiven je najbolji rezultat od 59,76% točnosti i dokazano da vremenski raspon snimanja podataka nema veze na kvalitetu podataka.

Literatura

- Bang, J. S., Jeong, J. H., & Won, D. O. (2020). Classification of Visual Perception and Imagery based EEG Signals Using Convolutional Neural Networks. <https://doi.org/10.48550/arXiv.2005.08842>
- Bobrov, P., Frolov, A., Cantor, C., Fedulova, I., Bakhnyan, M., & Zhavoronkov, A. (2011). Brain-Computer Interface Based on Generation of Visual Images. <https://doi.org/10.1371/journal.pone.0020674>
- Esfahani, E. T., & Sundararajan, V. (2012). Classification of primitive shapes using brain-computer interfaces. <https://doi.org/10.1016/j.cad.2011.04.008>
- Gramfort, A., Luessi, M., Larison, E., Engemann, D. A., Strohmeier, D., Brodbeck, C., Goj, R., Jas, M., Brooks, T., Parkkonen, L., & Hämäläinen, M. (2013). *MEG and EEG data analysis with MNE-Python*. *Frontiers*. <https://doi.org/10.3389/fnins.2013.00267>
- Kumar, K., & Thakur, G. M. (2012). Advanced Applications of Neural Networks and Artificial Intelligence: A Review. <https://doi.org/10.5815/ijitcs.2012.06.08>
- Llorella, F. R., Iáñez, E., Azorín, J. M., & Patow, G. (2021). Classification of imagined geometric shapes using EEG signals and convolutional neural networks. <https://doi.org/10.1016/j.neuri.2021.100029>
- O'Shea, K., & Nash, R. (2015). An Introduction to Convolutional Neural Network. <https://doi.org/10.48550/arXiv.1511.08458>
- Stefan Haufe, Vadim V. Nikulin, Klaus-Robert Müller, & Guido Nolte. (2012). A critical assessment of connectivity measures for EEG data: A simulation study. *ELSEVIER*.
- Wang, S. C. (2003). Artificial Neural Network. https://doi.org/10.1007/978-1-4615-0377-4_5
- Wolpaw, J. R., Birbaumer, N., Heetderks, W. J., McFarland, D. J., Peckham, P. H., Schalk, G., Donchin, E., Quatrano, L. A., Robinson, C. J., & Vaughan, T. M. (2000). Brain-

computer interface technology: a review of the first international meeting. <https://doi.org/10.1109/tre.2000.847807>

Zhang, X., Yao, L., Huang, C., Kanhere, S. S., Zhang, D., & Zhang, Y. (2020). Brain2Object: Printing Your Mind from Brain Signals with Spatial Correlation Embedding. <https://doi.org/10.48550/arXiv.1810.02223>

Zayegh, A., & Al Bassam, N. (2018). Neural Network Principles and Applications. *Digital Systems*. doi: 10.5772/intechopen.80416

Ajit, A., Acharya, K., & Samanta, A. (2020). A Review of Convolutional Neural Networks. *2020 International Conference On Emerging Trends In Information Technology And Engineering (Ic-ETITE)*. 10.1109/ic-etite47903.2020.049

Basha, S., Dubey, S., Pulabaigari, V., & Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112-119. 10.1016/j.neucom.2019.10.008

Garbin, C., Zhu, X., & Marques, O. (2020). Dropout vs. batch normalization: an empirical study of their impact to deep learning. *Multimedia Tools And Applications*, 79(19-20), 12777-12815. doi: 10.1007/s11042-019-08453-9

Jung, W., Jung, D., Kim, B., Lee, S., Rhee, W., & Ahn, J. (2019). Restructuring Batch Normalization to Accelerate CNN Training. doi: <https://doi.org/10.48550/arXiv.1807.01702>

El Naqa, I., & Murphy, M. (2015). What Is Machine Learning?. *Machine Learning In Radiation Oncology*, 3-11. doi: 10.1007/978-3-319-18305-3_1

Graham, B. (2015). Fractional Max-Pooling. <https://doi.org/10.48550/arXiv.1412.6071>

Sažetak i ključne riječi

Neuralne mreže su sredstvo za strojno učenje (eng. *machine learning*) u kojem računalo nastoji prepoznati odnose u skupu podataka kroz proces koji oponaša način na koji funkcionira ljudski mozak. Strojno učenje je znanstvena disciplina koja se bazira na osmišljanju algoritma koji će pomoću skupa podataka učiti na određenim primjerima (Naqa i Murphy, 2015). Konvolucijske neuralne mreže su podskup neuralnih mreža koja se najviše primjenjuje za treniranje modela povezanih sa slikama. Ovaj rad istražuje ideju o klasifikaciji geometrijskih tijela pomoću EEG podataka. EEG podaci prikazani su u protoku voltaže, a za bolji prikaz mozga bolje je koristiti više EEG mjerenja signala tj. više elektroda koje su smještene svuda oko površine mozga. Snimanje EEG podataka napravljeno je putem uređaja OpenBCI Cyton + Daisy pri čemu su podaci snimani sa jednim ispitanikom. Kako bi podaci bili što čišći i relevantniji, soba ima slabije osvjetljenje te ne dolazi do bilo kakvog prodora buke ili ostalih vanjskih smetnji. Nakon snimanja skupa podataka, isti su obrađeni kako bi bili kompatibilni sa Conv2D slojem. Izvorni kod dostupan je na GitHub-u: <https://github.com/David-Sajina/OpenBCI>

Ključne riječi – Strojno učenje, neuralne mreže, konvolucijske neuralne mreže, elektroencefalografija, BCI sustav