



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV INTELIGENTNÍCH SYSTÉMŮ

DEPARTMENT OF INTELLIGENT SYSTEMS

IDENTIFIKACE A VERIFIKACE OSOB S VYUŽITÍM EEG

PERSON IDENTIFICATION AND VERIFICATION USING EEG

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

VEDOUcí PRÁCE

SUPERVISOR

ROLAND ŽITNÝ

Ing. JAN TINKA

BRNO 2021

Zadání bakalářské práce



Student: **Žitný Roland**
Program: Informační technologie
Název: **Identifikace a verifikace osob s využitím EEG**
Person Identification and Verification Using EEG

Kategorie: Uživatelská rozhraní

Zadání:

1. Nastudujte problematiku analýzy EEG v rozhraních mezi mozkiem a počítačem (BCI) za účelem identifikace a verifikace osob. Seznamte se se zařízením OpenBCI. Prostudujte metody strojového učení pro rozpoznávání EEG signálů.
2. Navrhněte vlastní implementaci rozpoznávání EEG signálů pro účely identifikace a verifikace osob a nad tím postavenou aplikaci, která toto bude demonstrovat.
3. Navrženou aplikaci implementujte.
4. Ověřte správnost fungování vaší aplikace na lidech, pokud to umožní epidemiologická situace. Navrhněte možné pokračování práce. Klíčové vlastnosti práce prezentujte formou krátkého videa a plakátu.

Literatura:

- Wolpaw, J. a Wolpaw, E. W., eds. Brain-computer interfaces: principles and practice. Oxford University Press, 2012. ISBN 978-0-19-538885-5.
- Siuly, S., Li, Y. a Zhang, Y. EEG Signal Analysis and Classification. Springer International Publishing, 2016. Health Information Science. ISBN 978-3-319-47652-0. Dostupné z: <http://link.springer.com/10.1007/978-3-319-47653-7>.
- Cohen, M. X. Analyzing neural time series data: theory and practice. The MIT Press, 2014. Issues in clinical and cognitive neuropsychology. ISBN 978-0-262-01987-3.
- Luck, S. J. An introduction to the event-related potential technique. Second edition. The MIT Press, 2014. ISBN 978-0-262-52585-5.

Pro udělení zápočtu za první semestr je požadováno:

- Body 1, 2 a částečně bod 3.

Podrobné závazné pokyny pro vypracování práce viz <https://www.fit.vut.cz/study/theses/>

Vedoucí práce: **Tinka Jan, Ing.**

Vedoucí ústavu: Hanáček Petr, doc. Dr. Ing.

Datum zadání: 1. listopadu 2020

Datum odevzdání: 12. května 2021

Datum schválení: 11. listopadu 2020

Abstrakt

Cielom práce bolo vytvoriť rozhranie medzi mozgom a počítačom, ktoré spoľahlivo identifikuje a verifikuje osobu za pomoci jej elektroencefalografických signálov. Vytváranie profilu užívateľa a jeho overovanie je založené na spracovávaní reakcií na jeho vlastnú tvár a tvár cudzích alebo známych osôb. Pre filtráciu signálov sa využívajú algoritmy ako pásmová prepust' a odstraňovanie šumu pomocou vlnkovej transformácie. Klasifikácia reakcií sa vykonáva pomocou konvolučnej neurónovej siete alebo lineárnej diskriminačnej analýzy. Priemerná presnosť lineárnej diskriminačnej analýzy je 66,2 % a konvolučnej neurónovej siete je 58,7 %. Maximálna dosiahnutá presnosť bola pri lineárnej diskriminačnej analýze a to 93,7 %.

Abstract

The aim of this work was to create a brain-computer interface that reliably identifies and verifies a person using his electroencephalographic signals. Creating a user profile and verifying it is based on processing reactions to his own face, and the face of strangers or acquaintances. Algorithms such as bandpass and noise removal using wavelet transformation are user to filter signals. The classification of reactions is performed using a convolutional neural network or linear discriminant analysis. The average accuracy of the linear discriminant analysis is 66.2 % and of the convolutional neural network is 58.7 %. The maximum achieved accuracy was with linear discriminant analysis and at 93.7 %.

Kľúčové slová

mozgová aktivita, elektroencefalografia, EEG, rozhranie medzi mozgom a počítačom, BCI, identifikácia, verifikácia, filtrácia signálu, pásmová prepust', vlnková transformácia, klasifikácia, vlastná tvár, cudzia tvár, P300, N170, N250, ERP, artefakty, neurónová sieť, lineárna diskriminačná analýza, CNN, LDA

Keywords

brain activity, electroencephalography, EEG, brain-computer interface, BCI, identification, verification, signal filtering, bandpass, wavelet transformation, classification, self face, non-self face, P300, N170, N250, ERP, artifacts, neural network, linear discriminant analysis, CNN, LDA

Citácia

ŽITNÝ, Roland. *Identifikace a verifikace osob s využitím EEG*. Brno, 2021. Bakalárska práca. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Jan Tinka

Identifikace a verifikace osob s využitím EEG

Prehlásenie

Prehlasujem, že som túto bakalársku prácu vypracoval samostatne pod vedením pána Ing. Jana Tinky. Uviedol som všetky literárne pramene, publikácie a ďalšie zdroje, z ktorých som čerpal.

.....
Roland Žitný
6. mája 2021

Podakovanie

Rád by som poďakoval svojmu vedúcemu práce pánovi Ing. Janovi Tinkovi, za užitočné rady, flexibilitu a ústretovosť pri tvorbe tejto práce.

Obsah

| | | |
|----------|--|-----------|
| 1 | Úvod | 2 |
| 2 | Elektroencefalografia a rozhranie medzi mozgom a počítačom | 3 |
| 2.1 | Elektroencefalografia | 3 |
| 2.2 | Rozhranie medzi mozgom a počítačom | 7 |
| 2.3 | Artefakty a filtrácia EEG signálov | 11 |
| 2.4 | Klasifikácia a preklad EEG charakteristík | 14 |
| 2.5 | Návrhové vzory BCI | 17 |
| 3 | Návrh systému pre identifikáciu a verifikáciu osôb s využitím EEG | 20 |
| 3.1 | Cieľ a popis činnosti systému | 20 |
| 3.2 | Zaznamenávanie EEG signálov subjektu | 23 |
| 3.3 | Stimulácia mozgu užívateľa a prístupujúce možnosti systému | 23 |
| 3.4 | Filtrácia a extrakcia vlastností EEG signálov | 25 |
| 3.5 | Preklad vlastností, interpretácia a odpoveď systému | 25 |
| 4 | Implementácia navrhnutého systému | 27 |
| 4.1 | Užívateľské rozhranie a možnosti systému | 28 |
| 4.2 | Zaznamenávanie EEG signálov a použité zariadenie | 31 |
| 4.3 | Tvorba stimulov a ich prezentácia | 31 |
| 4.4 | Spracovanie charakteristík EEG signálov | 33 |
| 4.5 | Klasifikácia a riadenie systému | 34 |
| 5 | Testovanie a vyhodnotenie funkcionality systému | 38 |
| 5.1 | Metodika a výsledky testovania | 38 |
| 5.2 | Vyhodnotenie funkcionality systému | 40 |
| 6 | Záver | 42 |
| | Literatúra | 43 |
| | Zoznam príloh | 45 |
| A | Obsah pamäťového média | 46 |
| B | Plagát | 47 |

Kapitola 1

Úvod

Zabezpečenie a ochrana citlivých údajov je neoddeliteľným aspektom života bežnej populácie, ale aj veľkých súkromných alebo štátnych organizácií. Pri prístupe k chráneným údajom je potrebné pristupujúcu osobu overiť, aby sa k chráneným údajom dostali iba oprávnené osoby. Takáto činnosť je často sprevádzaná rizikom vystavenia svojich prístupových údajov okoliu, čo umožňuje ich zneužitie. Využitie rozhrania medzi mozgom a počítačom, kde sa mozgové signály využijú ako prístupové údaje, takéto bezpečnostné riziko eliminuje vďaka nemožnosti zaznamenania mozgových signálov bez vedomia užívateľa a odcudzenia, alebo syntetizácie takýchto údajov. Takéto využitie mozgových signálov by prinieslo nový spôsob zabezpečenia a ochrany citlivých údajov, kde by užívateľ nevykazoval okoliu žiadne prístupové informácie, ktoré by sa dali zneužiť.

Cielom tejto práce je navrhnúť, implementovať a otestovať takýto autentizačný systém, ktorý je použiteľný v praxi. Dôležité kritéria takéhoto systému sú užívateľská prívetivosť, rýchlosť a presnosť. Užívateľ nemôže stráviť nadmerne dlhú dobu pri registrácii a prihlasovaní do systému a jeho overenie musí prebehnúť rýchlo a spoľahlivo.

Motiváciou riešenia tejto problematiky sú narastajúci záujem a počet štúdií ohľadne mozgových signálov a rozhrania medzi mozgom a počítačom. Táto tematika má veľký potenciál využitia v bezpečnostnej sfére vďaka unikátnosti špecifických mozgových signálov vznikajúcich pri reakciách užívateľa na fotografie vlastnej tváre.

Kapitola 2 predstavuje znalosti potrebné k pochopeniu problematiky tejto práce. Rozoberá princípy spracovania mozgových signálov a ich využitie v rozhraní medzi mozgom a počítačom. Návrh a implementáciu autentizačného systému, ktorý identifikuje resp. verifikuje osoby na základe mozgových signálov, predstavujú kapitoly 3 respektíve 4. Postup testovania a vyhodnotenie funkcionality autentizačného systému je predstavený v kapitole 5, ktorá zhodnocuje dosiahnuté výsledky. Záver a zhrnutie dosiahnutých výsledkov predstavuje kapitola 6.

Kapitola 2

Elektroencefalografia a rozhranie medzi mozgom a počítačom

Táto kapitola uvádza znalosti, ktoré sú potrebné k pochopeniu problematiky a jednotlivých postupov, ktorým sa táto práca venuje. Sekcia 2.1 rozoberá elektrické signály mozgu, ich vlastnosti a metódy zaznamenávania. Následne sekcia 2.2 predstavuje rozhranie medzi mozgom a počítačom, jeho princípy, funkcie a metódy spracovávania sledovaných vlastností EEG signálov. Sekcia 2.3 oboznamuje čitateľa o nežiadúcich vlastnostiach EEG signálu a jednotlivých metódach využívaných k ich odstráneniu. Proces riadenia aplikácie a jeho princípy uvádza sekcia 2.4 a jednotlivé návrhové vzory pre tvorbu rozhrania medzi mozgom a počítačom sekcia 2.5. Na konci sekcie 2.3 a 2.4 sú predstavené možné knižnice, ktoré slúžia k riešeniu preberaných problémov.

2.1 Elektroencefalografia

Zachytávanie elektrických signálov mozgu pomocou elektroencefalografie a ich využitie je lacná a pohodlná metóda. V dnešnej dobe je dostupná v podobe veľkého množstva komerčných zariadení ako napríklad OpenBCI¹, ktoré sú prenosné a umožňujú bezdrôtové zapojenie. Tieto zariadenia zabezpečujú využitie takýchto elektrických signálov pre riadenie aplikácií.

Ludský mozog pozostáva približne zo 100 miliárd neurónov², ktorých elektrochemická charakteristika umožňuje prenášať elektrické signály vďaka ktorým komunikujú medzi sebou [26][8]. Elektroencefalografia, ďalej označovaná ako EEG, je metóda merania elektrických potenciálov³, ktoré reflektujú elektrickú aktivitu komunikácie medzi neurónmi. Táto metóda umožňuje sledovať mozgové funkcie osoby v priebehu sledovaného času. Pre zaznamenanie elektrických signálov sa používajú elektródy, ktoré sú umiestnené na viacerých pozíciách hlavy. Ich počet sa typicky pohybuje od 1 do 256 elektród [26]. Zaznamenávanie EEG signálov je závislé na spôsobe aplikácií elektród, ich počte a umiestnení, vzorkovacej frekvencie⁴, výberom referenčnej elektródy a kontamináciou nežiadúcimi artefaktami, ktoré sú podrobnejšie rozobrané v sekcii 2.3 [30].

¹<https://openbci.com>

²Neurón – nervová bunka

³Elektrický potenciál – Popisuje energiu elektrického náboja, jednotka je volt (V).

⁴Vzorkovacia frekvencia – Definuje počet meraných vzoriek signálu za jednotku času.

Existujú dva hlavné prístupy k zaznamenávaniu EEG signálov, ktoré závisia na spôsobe zavedenia elektród a tie sú [22][26]:

- **Invazívny prístup** – Elektródy sú implantované do mozgu počas neurochirurgie.
- **Neinvazívny prístup** – Elektródy sú dočasne zavedené na pokožke hlavy.


Táto práca sa zaoberá len neinvazívnym prístupom.

Meranie EEG signálu prebieha bipolárne, čo znamená, že je vždy nutné použiť pár elektród na jeho zaznamenanie. Samotný signál je získaný vďaka odčítaniu napätia medzi elektródami daného páru. V tomto páre je jedna elektróda určená pre zaznamenávanie a druhá je referenčná. Takéto zachytávanie EEG signálov je závislé na elektrických potenciáloch oboch elektród a na umiestnení referenčnej elektródy [30].

Vlastnosti EEG signálov

EEG signály sa zvyčajne rozdeľujú podľa amplitúdy, frekvencie, tvaru, ale aj samotného umiestnenia elektród na pokožke hlavy [13]. Amplitúda⁵ EEG signálu sa typicky pohybuje od 1 do 100 μV a frekvencia⁶ sa pohybuje od 0,5 do približne 30 a viac hertzov [26]. EEG signály môžu v sebe obsahovať aj tzv. potenciály súvisiace s udalosťami, ktoré majú špecifickú amplitúdu a tvar, ako napr. komponent P300, N250 a N170, ktorých vlastnosti sú bližšie rozobrané v sekcii 2.5. Na základe frekvencie sa EEG signály rozdeľujú na tieto kategórie:

- **Aktivita delta** – Je asociovaná s hlbokým spánkom a jej frekvencia je v rozmedzí 0,5 až 4 Hz. Znakom aktivity delta je taktiež vysoká amplitúda [26]. Túto aktivitu je nemožné zaznamenať mimo spánku subjektu⁷ [24]. Obrázok 2.1 znázorňuje takýto signál.




Obr. 2.1: Aktivita delta ľudského mozgu. Prevzaté z [26] a upravené. Osa x predstavuje čas a osa y amplitúdu.

- **Aktivita theta** – Je v rozmedzí 4 až 8 Hz s amplitúdou vyššou ako 20 μV , a poukazuje na emocionálny stres, frustráciu, sklamanie, kreatívnu inšpiráciu a meditáciu [26]. Táto aktivita je dobre zaznamenateľná počas spánku [24]. Obrázok 2.2 znázorňuje takýto signál.

⁵Amplitúda signálu – maximálna hodnota signálu


⁶Frekvencia – počet opakovaní periodického deja za jednotku času

⁷Subjekt merania – osoba na ktorej je vykonávané EEG meranie




Obr. 2.2: Aktivita theta ľudského mozgu. Prevzaté z [26] a upravené. Osa x predstavuje čas a osa y amplitúdu.

- **Aktivita alpha** – Je v rozmedzí 8 až 12,9 Hz s amplitúdou medzi 20 a 60 μV . Táto aktivita je vykazovaná v prípade, že subjekt vykonáva duševnú, sluchovú alebo pohybovú aktivitu. Táto mozgová aktivita môže poklesnúť o 1 až 2 Hz pokiaľ je subjekt ospalý [24]. Zavreté oči alebo relaxácia túto aktivitu zvyšuje [26]. Obrázok 2.3 znázorňuje takýto signál.



Obr. 2.3: Alpha aktivita ľudského mozgu. Prevzaté z [26] a upravené. Osa x predstavuje čas a osa y amplitúdu.

- **Aktivita beta** – Je asociovaná s mentálnou aktivitou ako napr. riešenie problému a sústredenie, jej frekvencie sa pohybujú od 13 do 30 Hz [26]. Amplitúda tejto aktivity sa v 98 % pohybuje pod 25 μV [24]. Obrázok 2.4 znázorňuje takýto signál.




Obr. 2.4: Aktivita beta ľudského mozgu. Prevzaté z [26] a upravené. Osa x predstavuje čas a osa y amplitúdu.

- **Aktivita gamma** – Aktivita gamma sa preukazuje frekvenciou vyššou ako 30 Hz a jej maximálna frekvencia je zaznamenaná približne 100 Hz. Je asociovaná s kognitívnymi⁸ a motorickými⁹ funkciami [26]. Obrázok 2.5 znázorňuje takýto signál.

⁸Kognitívne funkcie – poznávacie funkcie

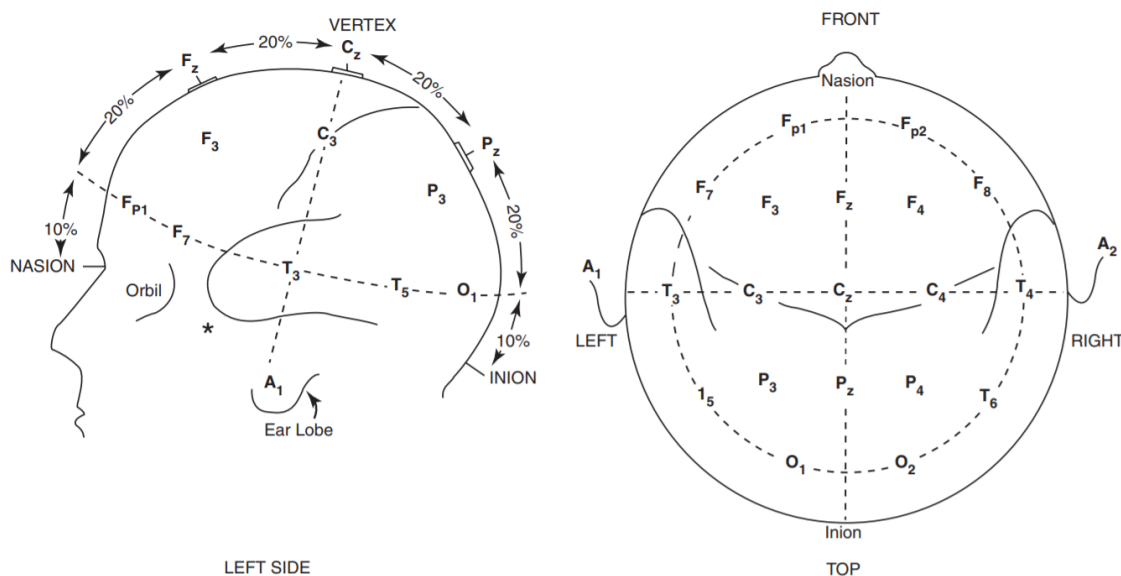
⁹Motorické funkcie – pohybové funkcie



Obr. 2.5: Aktivita gamma ľudského mozgu. Prevzaté z [26] a upravené. Osa x predstavuje čas a osa y amplitúdu.

Umiestnenie elektród na pokožke hlavy


Pre umiestnenie elektród sa využívajú štandardné medzinárodné stratégie ako stratégia „10-20“, stratégia „10-10“ a stratégia „10-5“ [30]. Tieto stratégie sa líšia počtom elektród a ich rozstupmi. Stratégia rozloženia elektród „10-20“ využíva 20 % dĺžky lebky ako rozostupy medzi elektródami a pozostáva z 21 elektród, z ktorých je jedna referenčná [24][25]. Obrázok 2.6 popisuje stratégiu „10-20“, kde na ľavej strane lebky sú nepárne označenia elektród a na pravej strane lebky sú párne označenia elektród. Stredný pás elektród je označený písmenom „z“ ako „zero“.



Obr. 2.6: Štandardné rozloženie elektród „10-20“. Prevzaté z [24].

Elektródy označené ako „F“ zaznamenávajú signály na čelnom laloku [24]. Čelný lalok je zodpovedný za osobnostné črty, emócie, riešenie problému, plánovanie a časťami reči a pohybu [26][13]. Označenie elektród „P“ predstavuje elektródy v oblasti temenného laloku, ktorý slúži pre rozpoznávanie, vnímanie podnetov, orientáciu a pohyb [24][26]. Elektródy označené ako „O“ patria okcipitálnemu laloku [24]. Tento lalok je zodpovedný za spracovanie vizuálnych podnetov [26][13]. Elektródy označené ako „T“ zaznamenávajú na temporálnom laloku, tento lalok je zapojený v rozpoznávaní sluchových podnetov, reči, vnímaní a pamäti [24]. Elektródy označené ako „C“, jediné nepredstavujú meranie v určitom laloku, ale umožňujú zaznamenávať typicky z ich okolia, a to je čelný lalok, temporálny lalok

a čiastočne temenný lalok. Označenie „A“ patrí ušným lalôčikom, ktoré môžu slúžiť ako referenčné elektródy [24]. Jednotlivé laloky mozgu sú zobrazené v obrázku 2.7.



Obr. 2.7: Jednotlivé laloky mozgu. Prevzaté zo stránky LumenLearning¹⁰ a upravené.

Význam EEG signálov v biometrii

Štúdie preukázali, že mozgová aktivita jedinca je definovaná jedinečným vzorom nervových dráh a preto môže byť využitá v biometrii [10]. Najväčšou výhodou využitia mozgových signálov, ako biometrický identifikátor je jej vysoká odolnosť voči zneužitiu. Takto využitý prvok pre biometriu nemožné zduplikovať [10][32].

Ďalšou významnou, ale zatiaľ experimentálnou vlastnosťou EEG signálov pri využití v biometrii je možnosť výmeny údajov, čo znamená, že pokiaľ príde k odcudzeniu tejto informácie je možné túto informáciu vymeniť. Takáto vlastnosť je pri iných biometrických metódach ako napr. pri využití odtlačkov prstov nemožná [10].

2.2 Rozhranie medzi mozgom a počítačom

Centrálna nervová sústava¹¹ reaguje na všetky vonkajšie podnety prostredia alebo vnútorné podnety tela. Tieto reakcie sú buď neuromuskulárne¹² alebo hormonálne [30][23]. Rozhranie medzi mozgom a počítačom, ďalej označované ako BCI z angl. brain-computer interface, poskytuje tejto sústave nový spôsob výstupu a umožňuje mozgu komunikovať s počítačom [26][23][28]. BCI prevádza aktivitu centrálnej nervovej sústavy na digitálny výstup, ktorý slúži na obnovu, náhradu alebo vylepšenie tejto sústavy [30][23]. Jednou z možných využití je napr. poskytnutie možnosti písania viet a slov pomocou označovania písmen očami. Takto označené slová a písmená sú následne syntetizované na reč pre ľudí s obmedzenou schopnosťou komunikácie. Ďalším príkladom je riadenie umelej náhrady končatiny pomocou

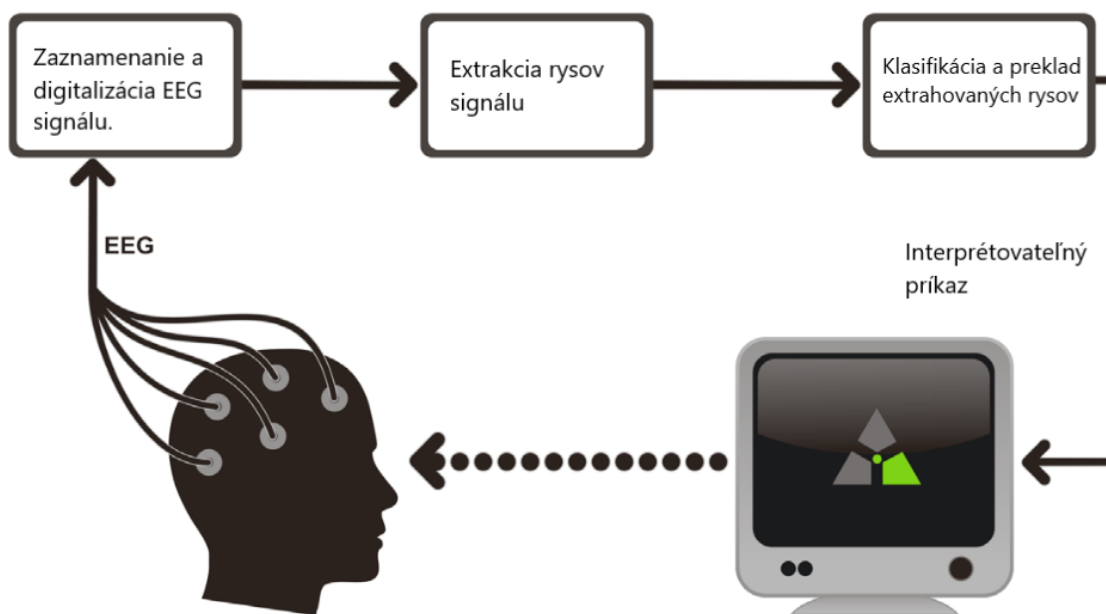
¹⁰<https://courses.lumenlearning.com/waymaker-psychology/chapter/reading-parts-of-the-brain/>

¹¹Centrálna nervová sústava (CNS) - Je nervové riadiace centrum organizmov. Skladá sa z mozgu a miechy.

¹²Neuromuskulárne – týkajúce sa nervov a svalov

aplikácie BCI pre osoby, ktoré prišli o jednu zo svojich končatín. Týmto sa dá zjednodušene povedať, že BCI je systém, ktorý prekladá mozgové signály na nový druh výstupu. Tento výstup následne slúži pre riadenie aplikácie.

Aktivita centrálnej nervovej sústavy sa dá monitorovať pomocou elektroencefalografie (predstavené v sekcii 2.1). Rozhranie medzi mozgom a počítačom spracováva tieto mozgové signály, extrahuje z nich špecifické vlastnosti a prevádza tieto vlastnosti na digitálny výstup, ktorý slúži na vykonanie určitých príkazov a akcií aplikácie [30]. Kľúčovým faktorom pre správne fungovanie BCI je výber pozícií umiestnenia elektród na pokožke hlavy, ktoré sú asociované s určitými motorickými a kognitívnymi funkciami (rozobrané v sekcii 2.1). Jednotlivé kroky systému BCI sú zaznamenanie a digitalizácia EEG signálov, extrakcia vlastností týchto signálov a ich klasifikácia a preklad na interpretovateľné príkazy. Tieto kroky predstavuje obrázok 2.8.



Obr. 2.8: Jednotlivé kroky systému BCI pozostávajú zo zaznamenania a digitalizácie EEG signálu (preberané v sekcii 2.1), extrakcie špecifických vlastnosti signálu a z prekladu extrahovaných vlastností na interpretovateľné príkazy aplikácie. Prevzaté z [4] a upravené.

Systém BCI vie produkovať dva typy výstupných príkazov:

- **Výber cieľa** – Subjekt merania podá zariadeniu BCI svoj cieľ, ktorý chce, aby daná aplikácia vykonala, a aplikácia riadená pomocou BCI tento cieľ dosiahne bez iných ovládacích prvkov [30][23]. Tento prístup je vhodnejší pre jednoduchšie aplikácie, kde je obmedzený počet možných príkazov a cieľov.
- **Riadenie procesu** – Subjekt a BCI spolu komunikujú každý detail vykonania určitého procesu riadenej aplikácie, ktorá spĺňa zámer subjektu [30][23]. Tento prístup je vhodnejší pre zložitejšie aplikácie, kde je veľký počet možných príkazov a cieľov.

Zjednodušeným popisom týchto dvoch prístupov je, že prístup výberu cieľa hovorí aplikácii čo má vykonať a prístup riadenia procesu hovorí aplikácii, ako ten cieľ dosiahnuť.

Extrakcia vlastností EEG signálu

Význam systému BCI je detekovať a kvantifikovať vlastnosti mozgových signálov, ktoré indikujú čo chce subjekt aby aplikácia vykonala. Tieto vlastnosti sa následne prekladajú na zamýšľané príkazy a akcie, ktorými je aplikácia riadená [30][23][9].


Extrakcia vlastnosti signálu je proces, ktorý rozlišuje relevantné vlastnosti signálu od irelevantného obsahu, ktoré je možné interpretovať [30]. Tento proces izoluje dôležité a relevantné vlastnosti EEG signálu od nadbytočných a nežiadúcich informácií a od rušivých elementov zvaných artefakty, ktoré su detailnejšie prebrané v sekcii 2.3. Takáto vlastnosť EEG signálu môže byť priamo nameraná hodnota, ako napr. rozdiel napätia medzi dvoma elektródami v špecifickom čase. Extrahovaná vlastnosť by mala spĺňať tieto atribúty [30]:

- Jej priestorová, časová alebo spektrálna charakteristika vie byť charakterizovaná pre individuálneho užívateľa alebo skupinu užívateľov.
- Vie byť pozmeňovaná užívateľom a použiteľná v kombinácii s inými vlastnosťami.
- Jej vzťah so zámerom užívateľa je stabilný, teda nemení sa zmenou času.

Cieľom extrakcie vlastností EEG signálu je transformácia základných vlastností signálu na vektor vlastností, ktorý sa prekladá na formu príkazov aplikácie. Extrakcia charakteristík EEG signálu pozostáva z troch krokov [30]:

1. Očistenie signálu od nežiadúcich artefaktov (podrobnejšie prebrané v sekcii 2.3) a zosilnenie relevantnej vlastnosti signálu.
2. Extrakcia vlastností z očisteného signálu.
3. Príprava vlastností pre preklad na špecifické príkazy aplikácie BCI. Táto fáza extrakcie vlastností EEG signálu slúži pre zlepšenie výkonu algoritmu prekladu, ktorý je bližšie prebraný v sekcii 2.4.

Po vyčistení EEG signálu od nežiadúcich artefaktov (prebrané v sekcii 2.3), je možné začať extrahovať žiadané vlastnosti signálu. Vzorok zaznamenaného signálu sa segmentujú do viacerých následných blokov, tzv. epoch, z ktorých je vytvorený vektor vlastností [30]. Bloky, ktoré sú pozitívne na výskyt žiadanej charakteristiky, sa následne posielajú algoritmu prekladu vlastnosti (predstavené v sekcii 2.4), kedy každý blok produkuje príkaz pre aplikáciu BCI [30]. Obrázok 2.9 predstavuje takéto rozdelenie signálu na epochy, kedy každý blok pozostáva z rovnakého časového okna.




Obr. 2.9: Príklad rozdelenie EEG signálu na jednotlivé bloky tzv. epochy, kedy každý blok predstavuje rovnaké časové okno a to 5,9 sekundy. Prevzaté z [26].

Najjednoduchšie metódy určenia výskytu žiadanej vlastnosti sú výber vrcholu a integrácia [30]. Výber vrcholu určuje minimálnu alebo maximálnu hodnotu z jednotlivých vzoriek sledovaného bloku a túto hodnotu využíva ako vlastnosť bloku daného EEG signálu. Integrácia cez všetky vzorky daného bloku sa taktiež dá využiť ako určenie vlastnosti EEG signálu [30]. Jednou z možností ako prezentovať vlastnosť bloku je jeho podobnosť s dopredu definovanou šablónou, kedy sa určuje miera podobnosti bloku a šablóny pomocou filtra s konečnou impulznou odozvou. Táto miera podobnosti následne určuje, či sa jedná o vlastnosť využiteľnú aplikáciou BCI [30]. Ďalšou významnou vlastnosťou EEG signálu sú potenciálne komponenty súvisiace s udalosťami, ako napr. komponent P300, N250 alebo N170. Tieto komponenty sa zvyčajne označujú písmenami „P“ alebo „N“, čo označuje pozitívnu alebo negatívnu polaritu tohto komponentu. Po tomto označení nasleduje číslo, ktoré predstavuje latenciu¹³ v milisekundách alebo poradovú pozíciu komponentu [12]. Tieto komponenty sú detailnejšie prebraté v sekcii 2.5

Frekvencia je taktiež možnou a často využívanou vlastnosťou daného EEG bloku, pre jej získanie slúžia metódy:

- **Pásmový výkon** – Označovaný ako „band power“. Využíva pásmovú prepust¹⁴ pre izoláciu požadovanej frekvencie. Následne sa hodnoty signálu umocnia, aby pozostával čisto z pozitívnych hodnôt (alternatíva je absolútna hodnota). Finálnym krokom je integrácia vzoriek signálu alebo dolná prepust¹⁵ [30]. Kroky tejto metódy sú predstavené v obrázku 2.10.




Obr. 2.10: Kroky výpočtu pásmového výkonu. Časť A predstavuje pôvodný signál. B predstavuje výsledok po aplikovaní pásmovej prepusti na pôvodne dáta v časti A. Časť C predstavuje umocnenie hodnôt signálu časti B. D je finálnym krokom, vyhladzovanie časti C pomocou dolnej prepusti. Prevzaté z [30].

¹³Latencia – reakčný čas, oneskorenie, meškanie

¹⁴Pásmová prepust (band pass) – Je filter, ktorý prepúšťa len signály určitej frekvencie.

¹⁵Dolná prepust (low pass) – Filter, ktorý neprepúšťa signál vyšších frekvencií.

- **Rýchla fourierova transformácia** – Má na vstupe N vzoriek zaznamenaného signálu a produkuje N frekvenčných vzoriek rovnomerne rozmiestnených na frekvenčnom rozsahu [30]. Obrázok 2.11 predstavuje túto metódu.



Obr. 2.11: Signály s časovou doménou sú zobrazené na ľavej časti a na pravej časti sú zobrazené výsledky rýchlej fourierovej transformácie. Prevzaté z [30].

- **Auto-regresné (AR) modelovanie** – Je alternatíva pre fourierové metódy výpočtu frekvenčného spektra signálu. Frekvenčné spektrum je určované pomocou filtra s nekonečnou impulznou odozvou. Touto metódou je možné dosiahnuť vyššie spektrálne rozlíšenie [30].

2.3 Artefakty a filtrácia EEG signálov

Ako väčšina komunikačných zariadení aj BCI čelí problému nežiadúcich vplyvov tzv. artefaktov, ktoré kontaminujú EEG signál a majú nežiadúci vplyv na samotné riadenie systému [30][11]. Tieto artefakty môžu pochádzať zo samotného prostredia, kde prebieha meranie mozgových vln v podobe elektromagnetického šumu z okolitých zariadení, alebo z tela ako napríklad svalová aktivita označovaná ako aktivita EMG (elektromyografická), z pohybu očí označované ako aktivita EOG (elektrooculografická), zo srdca označovaná ako aktivita EKG (elektrokardiografická) a zo samotného hardvéru BCI v podobe nestability elektród alebo šumu zosilňovačov [30][31][11]. Pre odstránenie rizika ovplyvnenia a narušenia EEG signálov je potrebné tieto artefakty filtrovať.

Cieľom filtrácie je zvýšiť pomer medzi signálom a šumom ktorý EEG signál ovplyvňuje, pretože artefakty sa môžu maskovať ako EEG signály a podávať falošný dojem riadenia systému BCI. Existujúce filtračné metódy sa rozdeľujú na tieto kategórie [30]:

- filtrácia v rámci frekvencie
- decimácia dát

- priestorová filtrácia
- odstránenie environmentálnych a biologických artefaktov

Filtrácia v rámci frekvencie

Signál je možné filtrovať takým spôsobom, že odstránime alebo potlačíme frekvencie, ktoré ležia mimo požadovaného rozsahu. Najznámejšími typmi filtrov sú [33]:

- **Dolná prepust' (low pass)** – Je filter, ktorý neprepúšťa signál vyšších frekvencií. V prípadoch, kedy systém BCI nepracuje s vysokými frekvenciami je možné využiť tento filter pre odstránenie EMG artefaktov, ktorých príznakom je vyššia frekvencia.
- **Horná prepust' (high pass)** – Je filter, ktorý potláča nízke frekvencie. Tento filter je vhodný pre odstránenie potenciálov tvorených na koži subjektu.
- **Pásmová prepust' (band pass)** – Je filter, ktorý prepúšťa určitý rozsah frekvencií. Tento filter je vhodné použiť pri odstraňovaní rušivých frekvencií z okolitých elektronických zariadení, alebo samotných elektród zaznamenávacieho zariadenia.

Napríklad pre prácu iba s Alpha aktivitou (popisujúcu obrázok 2.3) je vhodné použiť pásmovú prepust' 8-13 Hz. Pre vyvolávané potenciály ako P300 (predstavené v sekcii 2.5) je treba zväžiť použitie hornej prepusti s medznou frekvenciou medzi 0.1-0.5 Hz, aby sa zachovala nízkofrekvenčná charakteristika tejto informácie [30].

Decimácia dát

Pokiaľ je signál zaznamenávaný vzorkovacou frekvenciou, ktorá je príliš vysoká alebo inak nevhodná, je možné takto zaznamenaný signál decimovať. Táto filtrácia predstavuje periodické vylučovanie vzoriek zo záznamu. Pri decimácii signálu faktorom dvoch sa eliminuje každá druhá vzorka a tým efektívne zmení vzorkovacia frekvencia a dĺžka signálu na polovicu [30].

Priestorová filtrácia

Jeden meraný EEG kanál predstavujú dve elektródy (spomenuté v sekcii 2.1). Senzitivita tohto kanálu na špecifické zdroje je závislá na veľkosti a orientácii tohto zdroja voči miestu merania týchto dvoch elektród. To znamená, že správnym výberom umiestnenia týchto dvoch elektród, ktoré predstavujú kanál, je možné vytvoriť kanál, ktorý je senzitívnejší na požadované zdroje a menej senzitívnejší na nežiadúce zdroje. Tento výber sa nazýva priestorová filtrácia. Pokiaľ každá elektróda využíva rovnakú referenčnú elektródu, ktorej význam je preberaný v sekcii 2.1, je možné rekonštruovať ľubovoľnú množinu kanálov kombinovaním pôvodných kanálov [30].

Odstránenie environmentálnych a biologických artefaktov

Narušenie EEG signálu z okolitého prostredia môže predstavovať elektrické zariadenia ako napríklad samotné elektródy. Biologické narušenie môže pochádzať z EMG, EOG a ECG aktivity [30][11].

Elektrické alebo magnetické pole vytvárané okolitými zariadeniami môže ovplyvniť elektrické pole vo vnútri tela, ktoré vie byť zaznamenané elektródami. Toto narušenie je charakteristické spojitým sínusovým signálom o 50 Hz v Európe a Ázii, alebo 60 Hz v Amerike [30]. Na odstránenie takéhoto narušenia EEG signálu je možné použiť pásmovú zádrž pre odstránenie úzkeho frekvenčného pásma ako 55–65 Hz. Pre riešenie tohoto problému je taktiež možné využiť priestorovú filtráciu [30].

EMG, EOG a ECG artefakty sú náročné pre filtráciu pretože pripomínajú EEG signál. Tento problém je náročné vyriešiť frekvenčnými filtermi, pretože je šanca odstránenia žiaducich vlastností EEG signálu. Pre redukciiu takéhoto ovplyvnenia signálu je možné využiť priestorovú filtráciu alebo iné metódy, ktoré zachovávajú charakteristiku signálu [30].

Vlnková transformácia

Odstránenie šumu zo signálu je možné pomocou prahovania koeficientov vlnkovej transformácie. Táto metóda sa označuje ako „wavelet denoising“ a je schopná sledovať frekvenčnú a časovú charakteristiku signálu súčasne. Pri takomto čistení signálov dochádza k ich rozkladu na viacero multirezolučných¹⁶ častí v súlade so zvolenou vlnkovou funkciou, ktorá predstavuje filter. Táto vlnková funkcia určuje rozlíšenie signálu, čo predstavuje výpočet jeho podrobnej informácie. Najefektívnejšou vlnkovou funkciou je funkcia „db8“. [15][11]

Táto metóda je uprednostňovaná pred frekvenčnými filtráciami pretože pri odstraňovaní nežiaduceho šumu zachováva charakteristiku signálu. [15]

Knižnice poskytujúce filtračné metódy

SciPy¹⁷ je open-source knižnica určená pre programovací jazyk Python. Je to výhodná knižnica pre vedecké a technické výpočty. Modul `signal` tejto knižnice poskytuje všetky potrebné typy filtrov pre správnu úpravu a vyčistenie EEG signálu.

- `decimate(x, q, n=None, ftype='iir', axis=-1, zero_phase=True)` – Metóda ktorá umožňuje decimáciu filtrovaného signálu.
- `cheb1ap(N, rp)` – Metóda pre analógový filter dolnej prepusti.
- `p2hp(b, a, wo=1.0)` – Predstavuje metódu pre analógový filter hornej prepusti.

Ďalšou vhodnou knižnicou pre úpravu a čistenie EEG signálu je knižnica `brainflow`¹⁸, ktorá je určená pre zaznamenávanie a analýzu dát z bio-senzorov. Táto knižnica ponúka objekt `DataFilter`, ktorý obsahuje metódy pre filtráciu signálov ako napríklad:

- `perform_lowpass()` – Vykoná dolnú prepust.
- `perform_highpass()` – Vykoná hornú prepust.
- `perform_downsampling()` – Prevzorkuje data.
- `perform_fft()` – Vykoná rýchlu fourierovú transformáciu.
- `perform_bandpass()` – Vykoná pásmovú prepust.
- `perform_wavelet_denoising()` – Odstráni šum pomocou vlnkovej transformácie.

¹⁶Multirezolučná analýza – popisovanie signálu na rôznych úrovniach rozlíšenia

¹⁷<https://docs.scipy.org/doc/scipy/reference/signal.html>

¹⁸<https://brainflow.readthedocs.io/en/stable/index.html>

2.4 Klasifikácia a preklad EEG charakteristík

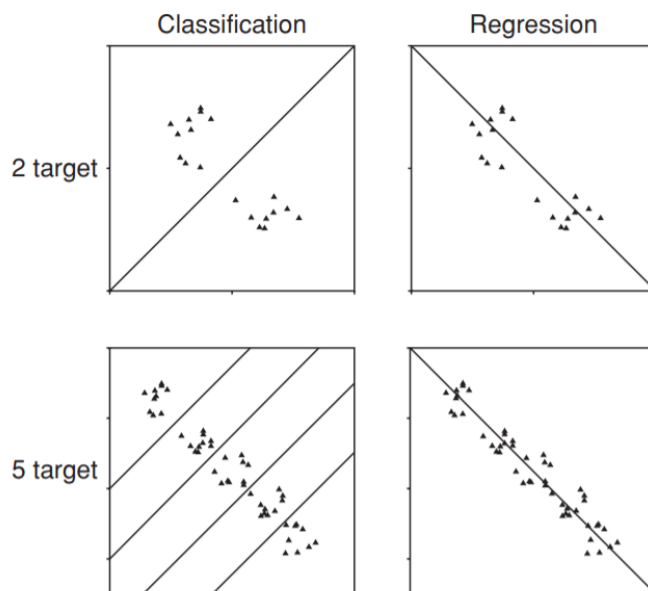
Vlastnosti EEG signálu určujú zámer užívateľa nepriamo, a preto musia byť preložené na špecifické príkazy a akcie aplikácie BCI. O túto činnosť sa starajú prekladové algoritmy. Hlavnou časťou prekladového algoritmu je model, ktorý predstavuje matematickú procedúru alebo mapovacie mechanizmy ako vyhľadávacia tabuľka [30]. Tento model berie na vstupe vektor charakteristík EEG signálu a jeho výstup sú predstavované príkazy, ktorým aplikácia rozumie. Výber modelu závisí na zložitosti aplikácie BCI. Napríklad amplitúda v určitom frekvenčnom pásme môže byť preložená ako binárna „1“ alebo „0“. Iným príkladom je skupina vlastností, ktoré sa dajú preložiť na trojdimenzionálne priestorové súradnice pre riadenie robotického ramena [30].

Model prekladového algoritmu

Modely prekladového algoritmu môžeme rozdeliť do dvoch skupín podľa toho, či je výstup modelu diskretný alebo spojitý [30]:

- **Klasifikačné modely** – Vstupné vlastnosti prekladajú na diskretné kategórie príkazov, ako napr. výber špecifických písmen. Takéto modely sú zvyčajne použité v aplikáciách, ktoré produkujú jednoduché „áno“ alebo „nie“ a cieľ alebo ne-cieľ, ako napr. aplikácie BCI založené na paradigme, ktoré pracuje s komponentom P300. Bližšie predstavenie komponentu P300 uvádza sekcia 2.5.
- **Regresné modely** – Vstupné vlastnosti prekladajú na spojitú premennú, napr. pre pohyb kurzoru. Takéto modely sú zvyčajne použité v aplikáciách, ktoré poskytujú spojitý výstup vo viacerých rozmeroch.

Porovnanie týchto dvoch typov modelov predstavuje obrázok 2.12.



Obr. 2.12: Na ľavej strane je zobrazený klasifikačný model, kde diagonálna čiara predstavuje funkciu, ktorá klasifikuje dáta na výstupy. Na pravej strane je regresný model, ktorý vytvára spojitý výstup. Prevzaté z [30].

Zoznam klasifikačných metód

Existujú dve hlavné skupiny klasifikačných prístupov, a to klasifikačné metódy s učiteľom a klasifikačné metódy bez učiteľa. Klasifikačné metódy s učiteľom sú parametrizované vďaka tréningovým dátam, ktoré sa skladajú z vektoru príznakov EEG signálu a jeho správneho prekladu, ktorý je určený ručne. Príkladom takýchto metód sú napr. LDA, SVM alebo NN, ktoré sú rozobraté v ďalšej časti. Klasifikačné metódy bez učiteľa nevyužívajú žiadne tréningové dáta pre parametrizáciu modelu, ale príslušnosť vlastnosti k danej triede určujú na základe jej charakteristiky ako napr. vzdialenosť vlastnosti od určitého bodu, ktorý predstavuje danú triedu. Príkladom takejto metódy je „K-means“, rozobratý ďalej [26].

Tento zoznam predstavuje vybrané klasifikačné metódy a ich princípy, ktoré je možné využiť aj pri regresnom modeli prekladu. Tento zoznam nepredstavuje konečný počet existujúcich metód.

- **(Linear Discriminant Analysis) LDA** – Lineárna diskriminačná analýza sa snaží maximalizovať rozdiely medzi zadanými triedami vstupných dát a produkuje toľko lineárnych funkcií, koľko je zadaných tried. Pri predpovedaní triedy k neoznačeným vstupným dátam sa vyberie tá trieda, ktorej príslušná lineárna funkcia bude dosahovať najvyššiu hodnotu. [16][20][17]
- **(Convolutional Neural Network) CNN** – Je klasifikačná metóda založená na hlbokom učení. Túto klasifikačnú metódu predstavuje model zložený z viacerých vrstiev ktoré môžu byť konvolučná vrstva, združovacia vrstva a (neurónová sieť) NN. Konvolučná vrstva je zodpovedná za produkciu vlastnosti zo zaznamenaného EEG signálu a združovacia vrstva je zodpovedná za redukciu rozmerov výstupu konvolučnej vrstvy. NN je zodpovedné za samotnú klasifikáciu [17].
- **(K-Nearest Neighbour) K-NN** – Je viac-triedna klasifikačná metóda, ktorá je založená na hlasovaní. Výpočet hlasovania je založený na euklidovskej vzdialenosti okolitých vlastností tzv. susedov od sledovanej vlastnosti. Počet týchto susedov sa označuje ako K a výsledok je vysoko závislý na tomto počte, ktorý sa zvyčajne určuje testovaním. Pri určení $K = 7$, algoritmus vyberie 7 najbližších vlastností k sledovanej vlastnosti a pokiaľ aspoň 4 z nich patria do triedy „1“, tak algoritmus vyhlási, že sledovaná vlastnosť patrí taktiež do tejto triedy „1“ [17].
- **(Neural Network) NN** – Neurónová sieť je nelineárna klasifikačná metóda, vhodná pre viacero klasifikačných tried. Štruktúra NN je založená na pridelovaní váh prepojeniam medzi neurónmi, ktoré predstavujú nelineárne funkcie [17].
- **(Support Vector Machine) SVM** – Je binárna klasifikačná metóda, ktorá prevádza vstup na vyššiu dimenziu pomocou polynómov a následne zapája rozhodovanie, ktoré určuje o ktorú triedu sa jedná [17].
- **K-means** – Je klasifikačná metóda založená na zhlukoch. Označenie K definuje počet zhlukov, pre ktoré sa určujú stredy. Každý údaj je následne pridelený k jednému zhlukom na základe jeho vzdialenosti k týmto stredom [17].

CNN – Konvolučná neurónová sieť

Konvolučná neurónová sieť je typom umelej neurónovej siete, ktorá je inšpirovaná spôsobom, akým fungujú biologické nervové systémy ako napr. ľudský mozog [19]. Umelé neurónové

systémy sa skladajú z vysokého počtu vzájomne prepojených výpočtových uzlov nazývaných neuróny, ktoré sa kolektívne učia zo vstupných dát s cieľom optimalizovať schopnosť predikcie tohoto systému [19][7].

Konvolučné neurónové siete sú primárne určené k rozpoznávaniu vzorov vo vstupných dátach [19]. Základná štruktúra týchto sietí sa skladá z troch typov vrstiev [19]:

- **Vstupná vrstva** – Načítava vstup zvyčajne vo forme viacrozmerného vektora a distribuuje ho do prvej skrytej vrstvy.
- **Skrytá vrstva** – Týchto vrstiev je zvyčajne viac ako jedna a slúži k tvorbe rozhodnutí s rešpektom k predchádzajúcej vrstve, kedy zväži, ako veľmi stochastická zmena poškodzuje alebo zlepšuje konečný výstup systému.
- **Výstupná vrstva** – Slúži k určeniu výstupu, teda pravdepodobnosti príslušnosti vstupných dát k triede.

Skryté vrstvy sa delia na konvolučné vrstvy, združovacie vrstvy a plne prepojené vrstvy. Konvolučné vrstvy slúžia k určeniu výstupu neurónov, ktoré sú prepojené s určitými časťami vstupu a to výpočtom skalárneho súčinu medzi ich váhami a prepojenými časťami vstupu. Združovacia vrstva vykonáva prevzorkovanie daného vstupu, čím zníži počet parametrov potrebných k ďalšiemu vyhodnoteniu. Plne prepojená vrstva slúži k vygenerovaniu ohodnotenia triedy, ktoré sa využije pre klasifikáciu. [19]

Knižnice poskytujúce klasifikačné metódy

Pre klasifikačné metódy je vhodná knižnica `scikit-learn`¹⁹, ktorá je určená pre strojové učenie v jazyku Python. Poskytuje radu možných klasifikačných metód ako napríklad:

- `LinearDiscriminantAnalysis()` – Implementuje metódu LDA.
- `SVC()` a `LinearSVC()` – Umožňujú využitie metód SVM, ktorá je efektívna vo vysokorozmerných priestoroch.
- `KMeans()` – Implementuje zhukovací metódu K-means.
- `MLPClassifier()` – Implementuje metódu plne prepojených neurónových sietí a to „Multi-layer Perceptron“.

Ďalšou vhodnou knižnicou je `tensorflow`²⁰, ktorej modul `keras` obsahuje všetko potrebné k vytvoreniu vlastnej konvolučnej neurónovej siete. Príklad zápisu troch základných vrstiev vyzerá takto:

- `Conv2D()` – Predstavuje konvolučnú vrstvu.
- `MaxPooling2D()` – Predstavuje združovaciu vrstvu.
- `Dense()` – Predstavuje plne prepojenú vrstvu.

Táto knižnica taktiež obsahuje ďalšie varianty týchto vrstiev a taktiež ďalšie ako napríklad vrstvu pre normalizáciu dát.

¹⁹<https://scikit-learn.org/stable/>

²⁰<https://www.tensorflow.org/>

2.5 Návrhové vzory BCI

Táto sekcia poskytuje prehľad základných vzorov riešenia problematiky BCI, ktoré uvádzajú spôsob vytvárania žiadanej mozgovej aktivity a prácu s ňou. Jednotlivé vzory riešenia je možné kombinovať v podobe hybridných systémov BCI.

Paradigmy predstavovania pohybu

Paradigmy predstavovania pohybu označované ako „Motor imagery paradigms“ predstavujú vzor riešenia aplikácie BCI, kedy užívateľ ovláda aplikáciu pomocou predstavovania si nejakého špecifického pohybu [2]. Je potvrdené, že predstava pohybu aktivuje časti mozgu, ktoré sú zodpovedné za vykonávanie samotného pohybu [21]. Najznámejšie paradigmy predstavovania pohybu sú SMR (sensorimotor rhythms) a IBK (imagined body kinematics).

Paradigma **SMR** je založené na predstavovaní si kinestetického²¹ pohybu veľkej časti tela ako napr. ruky, chodidla a jazyka, ktorého výsledkom je zmena mozgovej aktivity. Tento proces vyvoláva ERD²² v alpha aktivite (8–12 Hz) a v beta aktivite (18–26 Hz) [2][5]. Jednotlivé aktivity sú rozobrané v sekcii 2.1. Naopak relaxácia vyvoláva ERS²³[5]. Modulácie rytmu ERD a ERS sú najčastejšie zaznamenávané v oblastiach C3 a C4 (rozobrané v 2.1) a slúžia pre riadenie protetických²⁴ pomôcok [5]. Problémom pri tomto vzore je zdĺhavé učenie subjektu modulácie žiadaných frekvencií pre riadenie takéhoto zariadenia [2]. Najsledovanejšími vlastnosťami EEG signálu pri vzore SMR sú amplitúdy aktivity alpha a beta [2], ktorých bližšiu charakteristiku nájdete v 2.1.

Paradigma **IBK** rozširuje vzor SMR o možnosť určovania polohy, rýchlosti a prípadne zrýchlenia daného zariadenia [2]. Informácie riadenia pre tento vzor sú získavané z nízkych frekvencií (nižšie ako 2 Hz), kedy si subjekt predstavuje nepretržitý pohyb časti tela v multi-dimenzionálnom priestore [2].

Paradigmy externej stimulácie

Mozgová aktivita sa dá ovplyvniť vonkajšou stimuláciou ako napr. blikaním LED diódami a zvukmi [2]. Takto ovplyvnená mozgová aktivita sa dá zaznamenať a dekódovať pre riadenie aplikácie. Najznámejšími vzormi externej stimulácie sú vizuálna P300 a SSVEP (Steady state visual evoked potentials) [2].


Vizuálna komponent **P300** je vyvolaný ako odpoveď na zriedkavo prezentovanú udalosť, ktorá využíva tzv. „oddball paradigm“ [2]. Komponent P300 je pozitívny vrchol o veľkosti 5 až 10 mikro-voltov v rozpätí 220 až 550 ms po začiatku udalosti [2]. Tento komponent je definovaný ako priemerne zvýšenie amplitúdy časových záznamov mozgových signálov a je meraná v pozíciách Pz, Cz a Fz (rozobrané v sekcii 2.1). Výhodou tohto vzoru je vysoká presnosť a nevýhodou je možná únava subjektu pri sledovaní vizuálnych podnetov [2]. Obrázok 2.13 zobrazuje takúto P300 komponentu.

²¹Kinestetický – Subjekt si uvedomuje polohu pohyblivých orgánov v priestore.

²²Event-related desynchronization (ERD) – krátky útlm alebo blokácia rytmu

²³Event-related synchronization (ERS) – krátky vzostup amplitúdy rytmu

²⁴Protetická pomôcka – umelé zariadenie ktoré nahrádza stratenú časť tela




Obr. 2.13: P300 komponent po zobrazení vizuálneho podnetu, P3 predstavuje P300. Prevzaté z [2].

Pri paradigme **SSVEP** subjekt vyžaduje funkčnú kontrolu zraku, pretože táto metóda je vysoko náročná na pohyb očí. Subjekt musí posúvať pohľad a sústrediť sa na blikajúce podnety [2]. V tomto vzore sa konštantná frekvencia blikania podnetu odzrkadľuje na EEG signále, ktorý pozostáva z tej istej frekvencie [2]. Frekvencie týchto podnetov sa môžu pohybovať od nízkych frekvencií (1–3.5 Hz) po vysoké frekvencie (70–100 Hz) a byť vo forme blikajúcej LED diódy [2]. Subjektu sú predstavené viaceré blikajúce podnety, kedy si subjekt vyberie jeden pomocou zraku a potvrdenie tohto výberu prebieha pomocou sledovania EEG signálu, ktorý bude pozostávať z rovnakej frekvencie ako vybraný podnet. Výhodou tohto prístupu je jednoduché využitie kedy subjekt nemusí trénovať ovládanie aplikácie a umožňuje využitie viacerých možných príkazov aplikácie. Tento vzor je menej náchylný na ovplyvnenie artefaktami (bližšie popísané v sekcii 2.3) [2].


Paradigma vlastnej a cudzej tváre

Paradigma vlastnej a cudzej tváre označované ako „self face & non-self face paradigm“ využíva obrázky ako podnety mozgovej aktivity, kde časť „self face“ predstavuje obrázky tváre meraného subjektu a časť „non-self face“ predstavuje obrázky neznámych ale aj známych tvári ľudí [32]. V tomto vzore treba dbať na to, aby v jednotlivých opakovaníach obrázkov tváre subjektu zostal totožný a aby sa obrázky iných tvári časom menili [32]. Toto opatrenie je dôležité, aby sa predišlo adaptácií subjektu na jednotlivé podnety. Reakcie na vlastnú tvár majú vysokú variabilitu EEG signálov medzi jednotlivými subjektami, čo predstavuje výhodnú charakteristiku v rámci identifikácie osoby [32]. Psychologické a neurofyziologické štúdie taktiež zistili, že reakcie mozgovej aktivity na vlastnú tvár sa výrazne líšia od reakcií na tvár známych alebo neznámych osôb [32].

Obrázky 2.14 a 2.15 poskytujú rozbor takýchto reakcií, kedy rozdiel medzi amplitúdami reakcií subjektu na svoju tvár a reakciami na tvár cudzích osôb je znateľný.

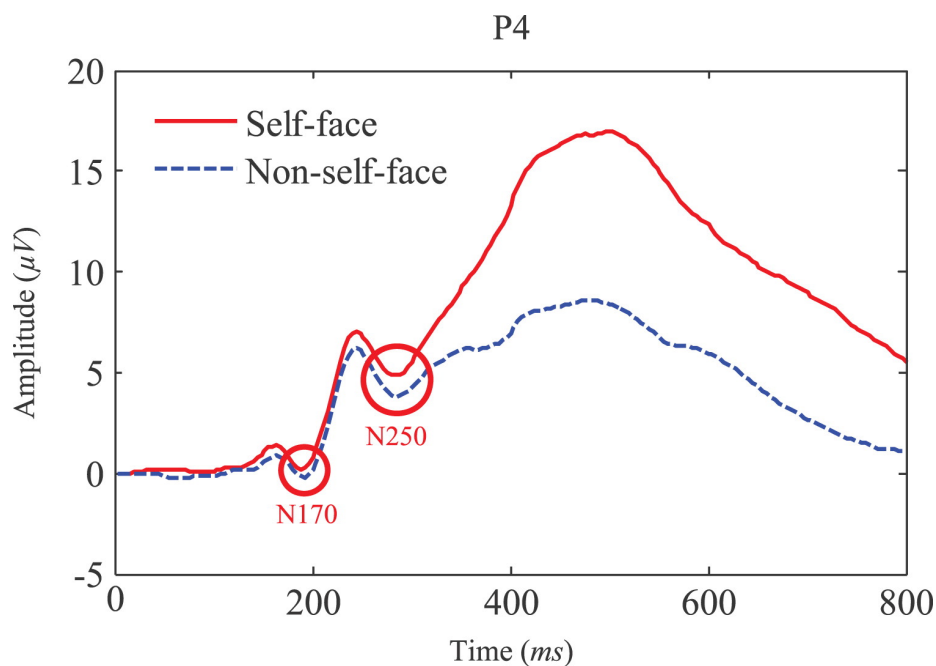


Obr. 2.14: Reakcie oprávneného užívateľa na obrázky svojej tváre. Prevzaté z [32] a upravené.



Obr. 2.15: Reakcie neoprávneného užívateľa na obrázky tváre oprávneného užívateľa. Prevzaté z [32] a upravené.

Obrázok 2.16 zobrazuje reakcie na tvár subjektu a na inú tvár, rozdiely sú znateľné v komponentoch N170 a N250, tieto reakcie boli zaznamenané v oblasti P4 (spomenuté v sekcii 2.1). Komponent N170 predstavuje negatívne vychýlenie amplitúdy a prebieha okolo 140 až 200 ms po prezentácii podnetu v podobe obrázka [32]. Komponent N250 je taktiež negatívne vychýlenie amplitúdy a je pozorovaná v časti mozgu, ktorá reaguje na spracovávanie tvári, ktorá je vysoko citlivá na rôzne typy tvárí [32].



Obr. 2.16: Reakcie na tvár subjektu a inú tvár, kde sú výrazné komponenty N170 a N250. Prevzaté z [32].

Pri tomto paradigme je taktiež možné zaznamenať komponentu P300 v prípade správneho prezentovania stimulov, ako v jednom z paradigiem externej stimulácie.

Kapitola 3

Návrh systému pre identifikáciu a verifikáciu osôb s využitím EEG

Táto kapitola rozoberá koncepciu systému, ktorý identifikuje a verifikuje osoby s využitím EEG a predstavuje jednotlivé kroky a ich details, ktoré sú nutné pre realizáciu zadaného systému. Sekcia 3.1 oboznamuje čitateľa o celkovej koncepcii systému a predstavuje jej jednotlivé kroky. Sekcia 3.2 popisuje navrhovaný spôsob zaznamenávania mozgovej aktivity a umiestnenia elektród na pokožke hlavy. Metódu vyvolávania potrebných reakcií užívateľa pre požadovanú funkcionálnosť systému predkladá sekcia 3.3. Potrebné filtračné techniky pre vyčistenie mozgových signálov a výber vhodných vlastností EEG signálov predstavuje sekcia 3.4. Preklad vlastností na interpretovateľné príkazy, ich spôsob interpretácie a možné výstupy systému rozoberá sekcia 3.5.

3.1 Cieľ a popis činnosti systému

Cieľom navrhovaného systému je identifikovať a verifikovať osobu pomocou jej EEG signálov (prebrané v kapitole 2, sekcii 2.1). Tento systém musí spĺňať základné kritériá aby bol použiteľný v praxi. Prvým kritériom je vysoká úspešnosť a spoľahlivosť v procese identifikácie a verifikácie a druhým kritériom je jednoduchosť využitia aplikácie a jej nízka časová náročnosť. Tieto dve kritériá spolu predstavujú nepriamu úmeru, kedy sa zvyšovaním presnosti a spoľahlivosti systému vytvára systém, ktorý je náročný na čas a úsilie užívateľa. Medzi týmito dvoma kritériami je potrebné nájsť vhodný pomer.

Primárnymi funkciami aplikácie bude registrácia, prihlásenie a identifikácia užívateľa. Proces registrácie slúži pre vytvorenie profilu užívateľa pomocou jeho individuálnych EEG charakteristík. V prípade procesu prihlásenia pôjde o overenie rovnosti alebo podobnosti EEG charakteristík prístupujúceho užívateľa do systému s jeho registrovaným profilom. Identifikácia užívateľa bude poskytovať prístupujúcejmu užívateľovi možnosť získania prístupových identifikačných údajov k registrovanému profilu na základe jeho EEG charakteristík. Tieto funkcie sú popísané na obrázku 3.1.

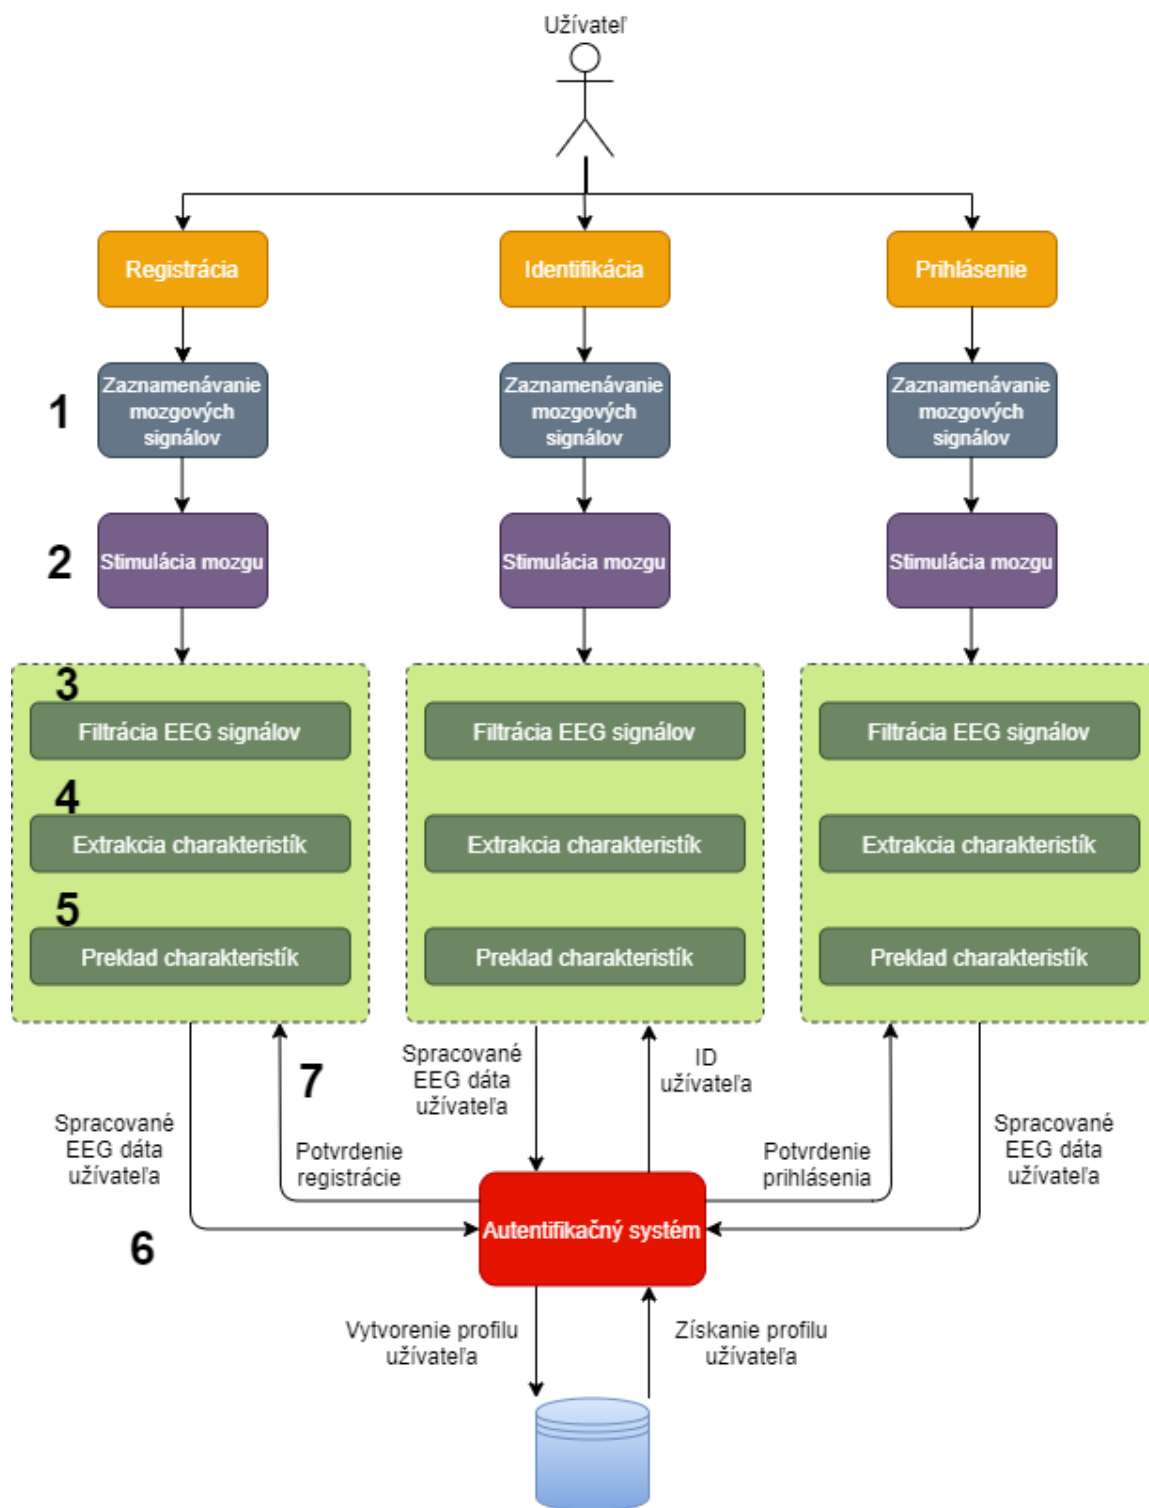
Rozdelenie konceptu identifikácie a verifikácie osôb s využitím EEG na jednotlivé kroky je zobrazené na obrázku 3.1 a predstavujú ich:

- 1 Zaznamenávanie EEG signálov** – Je proces, kedy je potrebné správne určiť metódu merania EEG signálov a jednotlivé lokácie mozgu, na ktorých budú efektívne zaznamenané zmeny v aktivite mozgu. Jednotlivé lokácie mozgu sú prebrané v ka-

pitole 2, sekcii 2.1. Toto zaznamenávanie EEG signálov bude prebiehať počas celej doby stimulácie užívateľa.

- 2 Stimulácia mozgu užívateľa** – Je najvýznamnejší krok, ktorý určuje akým spôsobom sa bude vyvolávať reakcia užívateľa, ktorej EEG charakteristiku (predstavené v kapitole 2, sekcii 2.1) je možné využiť ako prístupový údaj do systému. Individuálnosť tejto EEG charakteristiky musí byť vysoká, aby nenastala situácia zámieny užívateľov.
- 3 Vyčistenie a filtrácia EEG signálov** – Určuje metodiku vyčistenia EEG signálov od nežiadúcich artefaktov tak, aby sa zachovala významná charakteristika signálu. O artefaktoch a možných metódach filtrácie oboznamuje sekcia 2.3 v kapitole 2.
- 4 Extrakcia vlastností EEG signálov** – Je proces výberu a spracovania tých charakteristík zaznamenaného EEG signálu, ktoré je možné interpretovať na finálne príkazy aplikácie. Proces extrakcie takýchto vlastností je bližšie rozobraný v kapitole 2, sekcii 2.2.
- 5 Preklad vlastností EEG signálu** – Slúži na prevod extrahovaných charakteristík EEG signálu na interpretovateľné príkazy, ktoré slúžia pre riadenie aplikácie. Presnejší popis tohto procesu a jednotlivé metódy prekladu sú predložené v kapitole 2, sekcii 2.4.
- 6 Interpretácia preložených EEG charakteristík** – Predstavuje riadenie aplikácie pomocou vytvorených príkazov z EEG charakteristík.
- 7 Odpoveď systému užívateľovi** – Upovedomuje užívateľa o chode aplikácie a vzniknutých výsledkoch.

Jednotlivé kroky sú detailnejšie rozobrané v ďalších sekciách tejto kapitoly a implementačné detaily ku konkrétnym krokom rozoberá kapitola 4.



Obr. 3.1: Predstavenie jednotlivých krokov navrhnutého systému a to zaznamenávanie mozgovovej aktivity (1), stimuláciu mozgu (2), filtráciu zachytených signálov (3), extrakciu potrebných vlastností signálu (4), preklad týchto vlastností (5), interpretáciu vlastností (6) a samotnú odpoveď systému (7).

3.2 Zaznamenávanie EEG signálov subjektu


Zaznamenávanie EEG signálov bude prebiehať neinvazívnym spôsobom pomocou suchých elektród umiestnených na pokožke hlavy. Pre umiestnenie elektród som určil významné pozície na čelnom laloku (F3, F4) a v centrálnej časti (C3, C4), ktoré sú preberané v kapitole 2, sekcii 2.1. Tieto umiestnenia boli označené ako najvhodnejšie pre vzor „self face and non-self face“ v práci [32] (tento vzor predstavuje kapitola 2, sekcia 2.5) a jeho použitie je navrhované v ďalšej sekcii tejto kapitoly. Tento proces zaznamenávania prebieha počas celej doby stimulácie prístupujúceho užívateľa k systému.

3.3 Stimulácia mozgu užívateľa a prístupujúce možnosti systému

Pre vyvolávanie reakcií užívateľa som sa rozhodol využiť návrhový vzor „self face and non-self face“, ktorý je bližšie preberaný v kapitole 2, sekcii 2.5. Tento vzor som vybral na základe tvrdenia, že osoba, ktorá sa snaží o vydávanie sa za oprávnenú osobu nevykazuje správne reakcie na zobrazované stimuly vo forme fotky tváre tejto oprávnenej osoby. Toto tvrdenie je experimentálne potvrdené v práci [32]. Takáto vlastnosť vzoru „self face and non-self face“ je kľúčová pre správnu funkcionálnosť zadaného systému.

Vytvorené podnety v podobe fotiek tvári cudzích alebo známych osôb a fotky užívateľa je potrebné prezentovať prístupujúcemu užívateľovi na základe niekoľkých pravidiel. Z počiatku je potrebné upozorniť užívateľa, že takéto prezentovanie podnetov prebehne a to v podobe niekoľko sekundového odpočtu počas ktorého sa má užívateľ pripraviť. Následne prebehne náhodný výber jednotlivých podnetov, ktoré sú zobrazované na krátku dobu a to 300 ms, po ktorých nasleduje pauza na dobu 1000 ms. Náhodnosť podnetov je dôležitá, aby nebolo možné dopredu odhadnúť pôvod predstavovaného stimulu a spomenuté časy 300 a 1000 ms som takto zvolil, aby zaznamenávaný EEG signál dokázal obsiahnuť všetky potrebné komponenty vykazované pri použití vzoru „self face and non-self face“. Informácie o jednotlivých komponentoch nájdete v kapitole 2, sekcii 2.5.

Obrázok 3.2 uvádza príklad prezentácie podnetov.



Obr. 3.2: Príklad zobrazenia jednotlivých podnetov, kedy podnet je zobrazovaný po dobu 300 ms po ktorom nasleduje pauza 1000 ms. Prevzaté z [32] a upravené.

Pristupujúci užívateľ má tri možnosti prístupu k systému ako poukazuje diagram 3.1, a to registrácia, prihlásenie a identifikácia užívateľa.

Registrácia

Účelom registrácie je vytvorenie unikátneho profilu užívateľa, ktorý bude slúžiť k jeho prístupu do systému. V tomto procese je nutné aby užívateľ poskytol fotku svojej tváre pre spracovanie a vytvorenie podnetu. Možnosťami poskytnutia fotky tváre sú buď vyfotenie tváre pomocou aplikácie, alebo nahranie fotky zo súboru. Pri procese tvorby podnetu musí užívateľ dbať na správne a pravdivé poskytnutie údajov. Po úspešnom vytvorení podnetu registrovaného užívateľa nasleduje skutočná podstata registrácie a to zaznamenávanie reakcií užívateľa na predstavované stimuly. Percento výskytu vytvoreného podnetu užívateľa medzi ostatnými podnetmi, teda podnetmi zložených z fotiek tvárí cudzích alebo známych osôb je 20 %. Pri tejto stimulácii zachováваме náhodné poradie predstavovaných podnetov. Po získaní všetkých reakcií na predstavované podnety nasleduje fáza ich transformácie na tréningové dáta klasifikačného modelu (preberané v kapitole 2, sekcii 2.4), táto fáza je bližšie navrhnutá v sekcii 3.4.

Z takto vytvorených tréningových dát a podnetu užívateľa sa vytvorí profil, ktorý sa uloží do databázy užívateľov. Finálnou možnosťou registračného procesu je overenie správnosti registrácie a to testovacím prihlásením užívateľa do systému rozobranom ďalej.

Prihlásenie

Proces prihlásenie užívateľa do systému vykonáva overenie reakcií prístupujúceho užívateľa s hodnotami uloženými v jeho profile. Tento proces začína zadaním koho prístupujúci užívateľ má predstavovať, vďaka čomu systém vie akými podnetmi má stimulovať jeho mozog. Reakcie na tieto podnety sa budú vyhodnocovať pomocou klasifikačných metód (navrhnuté v sekcii 3.5), kedy prístupujúci užívateľ musí preukázať správnosť reakcií na jednotlivé podnety. Pokiaľ užívateľ v tomto procese zlyhá bude mu odopretý prístup do systému.

Identifikácia užívateľa

Identifikácia užívateľa je proces stanovenia identifikačných údajov prístupujúceho užívateľa, čo v zmysle prihlásenia do systému znamená koho daný užívateľ predstavuje. V tomto procese sa mozog užívateľa stimuluje podnetmi vytvorenými len registrovanými užívateľmi. Získané reakcie na predstavované podnety sa následne vyhodnocujú pomocou klasifikačných metód (navrhnuté v sekcii 3.5), kedy sa určuje príslušnosť týchto reakcií k jednotlivým podnetom. Výstupom tohto procesu sú identifikačné údaje toho registrovaného profilu, ku ktorého podnetu mal prístupujúci užívateľ najviac pozitívne hodnotených reakcií. Po tomto procese bude môcť prístupujúci užívateľ využiť získané identifikačné údaje pre prístup do systému pomocou procesu prihlásenia.

Pri procese identifikácie užívateľa je rizikovým faktorom počet registrovaných užívateľov. V prípade kedy bude počet registrovaných užívateľov príliš vysoký alebo príliš nízky, môže nastať problém s počtom prezentovaných stimulov. Ak je počet registrovaných užívateľov príliš vysoký, tak celkový počet predstavovaných podnetov bude taktiež vysoký a celkový čas potrebný pre vykonanie tohto procesu môže byť v určitých prípadoch fyzicky nezvládnuteľný zo strany užívateľa. Naopak v prípade príliš nízkeho alebo nulového počtu registrovaných užívateľov bude táto funkcia nepresná alebo nevykonateľná.

3.4 Filtrácia a extrakcia vlastností EEG signálov

Zaznamenávaná mozgová aktivita je často ovplyvnená nežiaducimi artefaktami, ktoré je nutné odstrániť pre správny chod aplikácie. Artefakty nájdete podrobne prebrané v kapitole 2, sekcii 2.3. Pre správne fungovanie aplikácie som sa rozhodol využiť dva typy filtrov. Jedným z filtrov je pásmová prepust', vďaka ktorej očistím signál od frekvencií medzi 50 a 60 Hz. Týmto filtrom dosiahnem elimináciu rušenia z rozvodnej siete a okolitých zariadení. Druhou filtračnou metódou je odstránenie šumu zo signálu pomocou prahovania koeficientov vlnkovej transformácie. Táto metóda je predstavená v kapitole 2, sekcii 2.3 a slúži pre odstránenie biologických artefaktov. Navrhnuté filtračné metódy umožňujú vykonať knižnice, ktoré su spomenuté na konci sekcii 2.3 v kapitole 2.

Po vykonaní očistenia signálov od rušivých elementov je potrebné extrahovať tie vlastnosti signálov, ktoré budú správne zachytávať individualitu reakcií užívateľa. V tomto kroku som sa rozhodol rozdeliť zaznamenanú mozgovú aktivitu na zhodné bloky o dĺžke 800 ms, kde týchto 800 ms začína v čase predstavenia stimulačného podnetu (navrhnuté v sekcii 3.3). Tieto bloky predstavujú reakciu užívateľa na predstavovaný podnet a ich počet je zhodný s počtom predstavovaných podnetov. Obrázok 2.16 popisuje charakteristiku takéhoto bloku, kedy významnou vlastnosťou bude komponent N170 a N250, ktoré bližšie predstavuje sekcia 2.5 v kapitole 2. Zo spôsobu stimulácie mozgu užívateľa, ktorá je navrhnutá v sekcii 3.3, usudzujem, že bloky budú taktiež obsahovať komponent P300. Tento komponent je taktiež podrobne prebraný v kapitole 2, sekcii 2.5. Ďalšou sledovanou vlastnosťou môže byť hodnota integrácie daných blokov, ktorú je nutné ale overiť a otestovať jej významnosť v procese klasifikácie (navrhnutý v 3.5).

Z takto spracovaných vlastností sa vytvorí vektor, ktorý sa následne využíva pre trénovanie klasifikačných metód. Tento proces trénovania je predstavený v kapitole 2, sekcii 2.4.

3.5 Preklad vlastností, interpretácia a odpoveď systému

Proces prekladu vlastností pomocou klasifikačných metód (prebrané v kapitole 2, sekcii 2.4) je najvhodnejšie riešiť binárnou formou, kedy klasifikačná metóda prehlasuje o jednotlivých reakciách či sú správne. To znamená, že pokiaľ je prístupujúcemu užívateľovi predstavený podnet vo forme tváre autorizovanej osoby, ktorú má užívateľ predstavovať a reakcia spĺňa požadované vlastnosti, tak táto reakcia je vyhodnotená ako binárna „1“ v opačnom prípade bude vyhodnotená ako binárna „0“.

Pre riadenie tohto procesu vyhodnotenia reakcií som sa rozhodol využiť lineárnu diskriminačnú analýzu a konvolučnú neurónovú sieť, ktoré sú detailnejšie rozobrané v kapitole 2, sekcii 2.4. Pre tieto metódy som sa rozhodol na základe tvrdení a testov v prácach [14] a [27], ktoré označujú tieto metódy za vysoko efektívne pri klasifikácii charakteristík tvorených pri paradigmatách externej stimulácie, pod ktoré taktiež patrí vzor „self face and non-self face“ a komponent „P300“. Podrobné predstavenie paradigiem externej stimulácie je v kapitole 2, sekcii 2.5.

Interpretácia vyhodnotených reakcií

Preložené reakcie vo forme binárnych „1“ a „0“ sa interpretujú aplikácii, kedy binárna „1“ predstavuje pozitívnu reakciu na daný podnet a binárna „0“ negatívnu reakciu. Pokiaľ užívateľ správne zareaguje na určitý počet podnetov, tak mu bude udelený prístup do systému.

V prípade procesu identifikácie užívateľa je vhodné zistiť maximálny počet pozitívnych reakcií na špecifický podnet, ktorý určuje prístupové identifikačné údaje daného užívateľa.

Odpoveď systému

Odpoveď systému je v podobe oznámenia o správnom vytvorení profilu užívateľa pri registrácii, oznámenia o potvrdení alebo odmietnutí prístupu do systému v procese prihlásenia a poskytnutia užívateľovi jeho identifikačných údajov v prípade procesu identifikácie užívateľa. Tieto odpovede sú zobrazené v obrázku 3.1.

Kapitola 4

Implementácia navrhnutého systému

V tejto kapitole sa preberajú kľúčové implementačné postupy pre jednotlivé kroky zhotovenia systému, ktorý identifikuje a verifikuje osoby s využitím EEG. Vznik a návrh týchto krokov spolu s kritériami správne fungujúceho systému predstavuje kapitola 3. Sekcia 4.1 predvádza ponúkané možnosti systému a vytvorené užívateľské rozhranie, ktoré hrá kľúčovú rolu pri zabezpečení kritéria o jednoduchosti ovládania aplikácie. V sekcii 4.2 sa predstavuje spôsob zaznamenávania EEG signálov a zariadenie použité pre túto činnosť. Techniku tvorby podnetov a ich prezentácie predstavuje sekcia 4.3, ktorá predkladá spôsob spracovania fotiek tváří užívateľov a zabezpečenie náhodnosti poradia takto vytvorených podnetov. Vhodná voľba počtu prezentovaných stimulov je kľúčová pre ďalšie kritérium a to pre nízku časovú náročnosť procesov aplikácie. Sekcia 4.4 predkladá spôsob spracovania EEG charakteristík. Tento krok sa zaoberá metódami využitými pre filtráciu EEG signálov a ich rozdelenie na použiteľné časové bloky, ktoré predstavujú reakciu na jednotlivé podnety. Klasifikáciu a celkové riadenie systému objasňuje sekcia 4.5. Správnosť implementácie spracovania EEG charakteristík a klasifikácie je kľúčová pre splnenie kritéria o vysokej úspešnosti a spoľahlivosti systému v procese identifikácie a verifikácie.

Implementácia systému prebiehala v jazyku Python verzie 3.8, ku ktorej bola vytvorená dokumentácia pomocou nástroja **Sphinx**¹. Táto dokumentácia sa nachádza na priloženom pamäťovom disku, ktorého obsah je popísaný v prílohe A. Primárnymi knižnicami, ktoré boli použité sú:

- **PyQt5**² – Je multiplatformová knižnica pre tvorbu desktopových a mobilných aplikácií. Pomocou nej bolo vytvorené celé grafické užívateľské prostredie. Jednotlivé dizajny okien je možné vytvárať pomocou aplikácie **Qt Creator**³, ktorá je založená na princípe „drag and drop“.
- **numpy**⁴ – Knižnica **numpy** je často využívanou knižnicou pri numerických výpočtoch v jazyku Python. Táto knižnica bola využitá hlavne pri spracovávaní hodnôt EEG signálu.

¹<https://www.sphinx-doc.org/en/master/>

²<https://pypi.org/project/PyQt5/>

³<https://www.qt.io/product/development-tools>

⁴<https://numpy.org/>

- **brainflow**⁵ – Táto knižnica je určená na získavanie a analýzu EEG, EMG, EKG a iných druhov údajov z biosenzorov. Knižnicu **brainflow** som využil pri zaznamenávaní, spracovávaní a filtrácii zaznamenatej mozgovej aktivity užívateľa.
- **opencv**⁶ – Je knižnica určená pre počítačové videnie a strojové učenie. Táto knižnica zabezpečuje vytváranie podnetu z fotky tváre užívateľa.
- **scikit-learn**⁷ – Je knižnica určená pre prediktívnu analýzu údajov. Táto knižnica poskytuje možnosť využitia lineárnej diskriminačnej analýzy pre klasifikáciu charakteristík EEG signálu.
- **tensorflow**⁸ – Je jediná náročnejšia knižnica na tomto zozname, lebo je potrebná špecifická verzia jazyku Python pre jej využitie. Táto knižnica slúži na vývoj a trénovanie modelov strojového učenia. Táto knižnica sa využíva pri návrhu a trénovaní konvolučnej neurónovej siete, ktorá slúži pre klasifikáciu charakteristík EEG signálov.

4.1 Uživatelské rozhranie a možnosti systému

Ako je spomínané v kapitole 3, tak jedným z dôležitých kritérií je jednoduchosť využitia aplikácie. Pre splnenie tohto kritéria som zostavil intuitívne grafické uživatelské rozhranie, ktoré vedie užívateľa počas všetkých ponúkaných procesov aplikácie a tými sú registrácia, prihlásenie a identifikácia.

Grafické uživatelské rozhranie je rozdelené na štyri typy okien. Úvodné okno slúži pre voľbu jedného z procesov registrácie, prihlásenia a identifikácie. Okno tvorby podnetu nasleduje po výbere procesu registrácie, kde sa vytvára stimulačný podnet užívateľa za pomoci fotky jeho tváre. Spoločným oknom pre všetky tri procesy je stimulačné okno, ktoré sa stará o prezentáciu jednotlivých podnetov užívateľovi. Finálne okno slúži pre oboznámenie užívateľa o stave systému, teda či sú vykonané procesy úspešné alebo nie. Všetky tieto okná boli vytvorené pomocou knižnice PyQt5, ktorá je predstavená v úvode tejto kapitoly. Táto sekcia ďalej uvádza jednoduché ukážky týchto okien.

Úvodné okno aplikácie

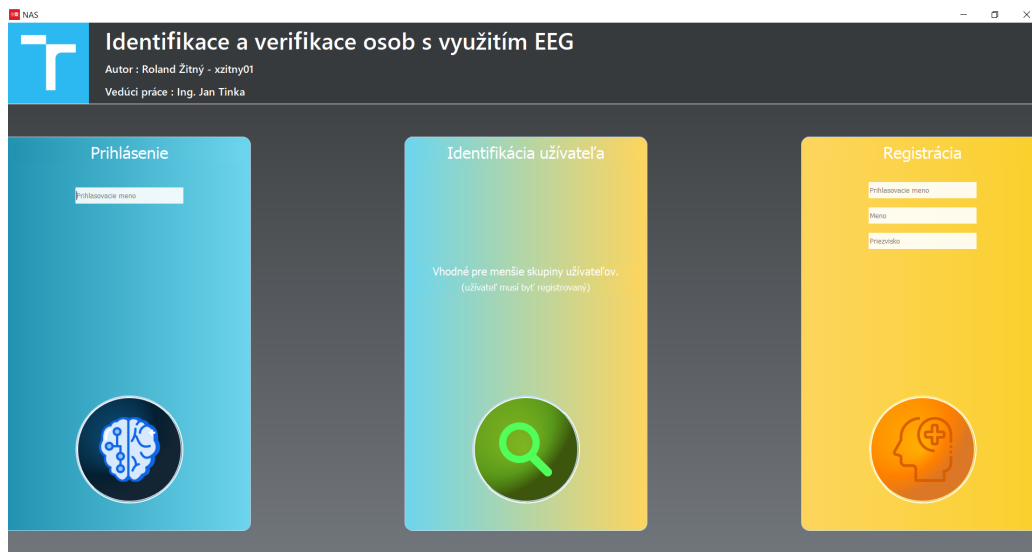
Úvodné okno aplikácie poskytuje užívateľovi možnosť voľby jedného z procesov registrácie, prihlásenia a identifikácie. Pri procese registrácie je potrebné zadať meno, priezvisko a identifikačné označenie podľa vlastného výberu, vďaka ktorým sa vytvorí objekt prístupujúceho užívateľa. S týmto objektom sa následne pracuje počas celého procesu registrácie a tvorí profil užívateľa. K týmto údajom sa v procese tvorby podnetu a samotného zaznamenávania EEG signálov pridávajú ďalšie atribúty (predstavené v sekciách 4.2 a 4.3). V procese prihlasovania musí prístupujúci užívateľ zadať identifikačné označenie svojho profilu pre získanie správneho podnetu, po ktorom začne stimulácia jeho mozgu (proces stimulácie je predstavený v sekcii 4.3). Proces identifikácie ako jediný nevyžaduje žiadne vstupné hodnoty a slúži pre stanovenie identifikačných prihlasovacích údajov prístupujúceho užívateľa. Predstavenie tohto okna je na obrázku 4.1.

⁵<https://brainflow.readthedocs.io/en/stable/>

⁶<https://opencv.org/>

⁷<https://scikit-learn.org/stable/>

⁸<https://www.tensorflow.org/>



Obr. 4.1: Úvodné okno aplikácie poskytujúce užívateľovi možnosť výberu jedného z procesov registrácie, prihlásenia a identifikácie.

Okno tvorby podnetu

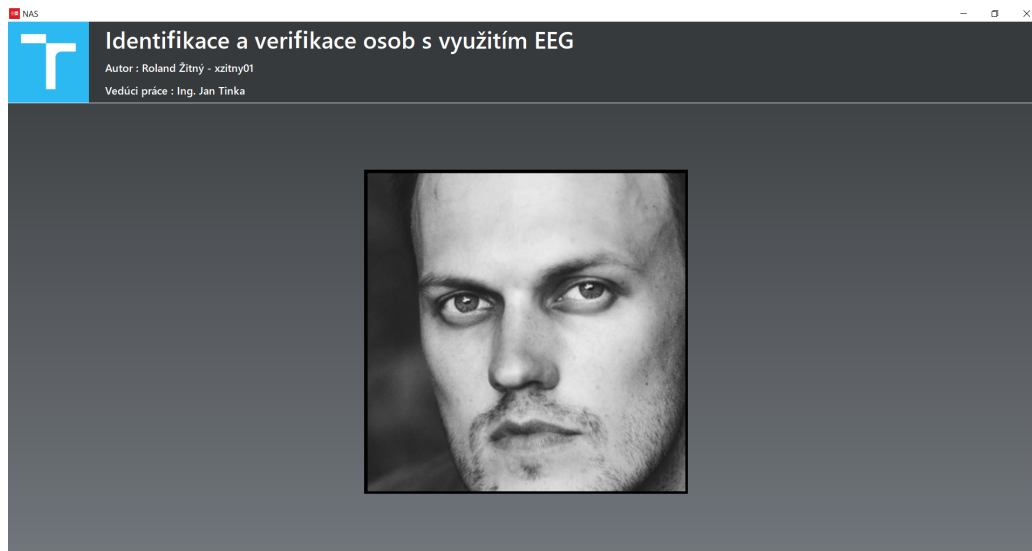
Toto okno sa využíva iba pri procese registrácie, kedy je potrebné vytvoriť stimulačný podnet z fotky tváre užívateľa. Užívateľ má dve možnosti poskytnutia fotky tváre a to buď vyfotenie tváre pomocou zapojených zariadení alebo nahraním fotky tváre zo súboru. Podrobnejší postup tvorby stimulačného podnetu je predstavený v sekcii 4.3. Takto vytvorený podnet sa uloží do atribútu objektu užívateľa spomenutom vyššie. Okno tvorby podnetu je zobrazené na obrázku 4.2.



Obr. 4.2: Okno tvorby podnetu, ktorého účelom je vytvoriť stimulačný podnet z fotky tváre registrujúceho sa užívateľa.

Stimulačné okno

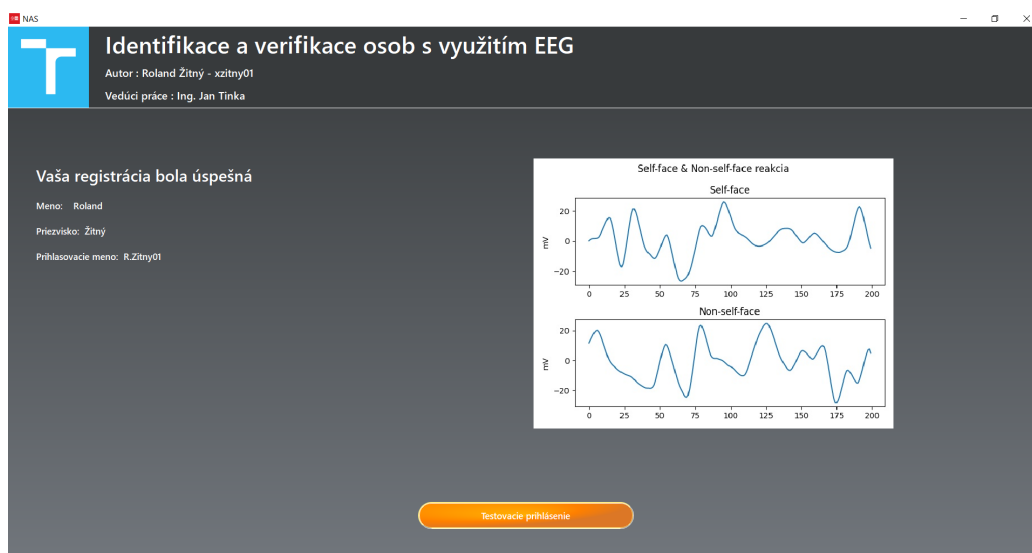
Stimulačné okno slúži na náhodné predstavovanie jednotlivých podnetov užívateľovi. Toto okno využívajú všetky možné procesy aplikácie. Bližší rozbor náhodného zobrazovania stimuloval preberá sekcia 4.3. Obrázok 4.3 predstavuje takéto okno.



Obr. 4.3: Stimulačné okno slúžiace pre stimuláciu mozgu užívateľa.

Finálne okno aplikácie

Finálne okno aplikácie slúži na oboznámenie užívateľa o výsledku zvoleného procesu. Finálne okno aplikácie pri procese registrácie predstavuje obrázok 4.4 a zobrazuje reakcie užívateľa na jednotlivé typy podnetov. Toto okno taktiež umožňuje užívateľovi testovacie prihlásenie do systému.



Obr. 4.4: Finálne okno aplikácie, ktoré upovedomuje užívateľa o chode a výsledku procesu aplikácie.

4.2 Zaznamenávanie EEG signálov a použité zariadenie

Pre zaznamenávanie EEG signálov bolo použité zariadenie od spoločnosti OpenBCI⁹, presnejšie išlo o zariadenie typu „Cyton + Daisy“. Pri využití tohto zariadenia je potrebné modulu BoardShim knižnice `brainflow` odovzdať informácie, ktoré poukazujú na to akým zariadením chceme zaznamenávať signály a na akom porte je toto zariadenie zapojené. Po zadaní týchto parametrov je možné spustiť zaznamenávanie. Proces zaznamenávania EEG signálov je potrebný po ukončení stimulácie (prebranej v sekcii 4.3) ukončiť, aby bolo možné získať zaznamenané dáta. Tieto dáta sa skladajú z hodnôt ktoré zaznamenali kanály tohto zariadenia a z jednotlivých časových záznamov týchto hodnôt.

Zo spracovaných dát sa následne vytvoria časové bloky závislé na výskyte stimulov. Tento proces je detailnejšie popísaný v sekcii 4.4. Zaznamenané a spracované signály sa následne uložia do objektu užívateľa, ktorý je spomenutý v sekcii 4.1.

4.3 Tvorba stimulov a ich prezentácia

Po poskytnutí fotografie tváre zo strany registrujúceho sa užívateľa je potrebné túto fotografiu upraviť do požadovanej formy. Farby tejto fotografie sa prevedú do odtieňov šedej a nasleduje využitie strojového učenia pre identifikáciu tváre v priestore fotografie. Takto upravená a identifikovaná tvár sa z fotografie vystrihne a tvorí samotný podnet užívateľa. Nasledujúci výpis kódu 4.1 predstavujú tento proces.

```
import cv2

...

image = cv2.imread(image_path)
image = cv2.cvtColor(image, cv2.COLOR_RGB2GRAY)
face_cascade = cv2.CascadeClassifier(cv2.data.harcascades
+ "haarcascade_frontalface_default.xml")
faces = face_cascade.detectMultiScale(image, 1.1, 4)

for (x, y, w, h) in faces:
    cv2.rectangle(image, (x, y), (x + w, y + h), (0, 0, 255), 2)
    faces = image[y:y + h, x:x + w]

# temporarily save the photo for further processing
cv2.imwrite(tmp_face_path, faces)

...
```

Výpis 4.1: Tvorba podnetu z fotografie tváre užívateľa.

Takto vytvorený podnet je následne potrebné uložiť do objektu užívateľa, ktorý je vytvorený na začiatku procesu registrácie. Pre zjednodušenie procesu uloženia takéhoto podnetu som sa rozhodol pred uložením zakódovať takto vzniknuté podnety pomocou kódovania `base64`.

Ako je spomenuté v kapitole 3, sekcii 3.3 tak prezentované podnety musia byť náhodné aby sa predišlo predikcii ich postupnosti zo strany užívateľa. Podľa návrhu musí byť 20 % zobrazovaných podnetov typu „self face“, teda zobrazovať fotografiu tváre užívateľa. Pri zvolení akéhokoľvek čísla za optimálny počet zobrazovaných podnetov vychádza, že každý piaty podnet musí predstavovať tvár užívateľa a ostatné musia byť typu „non-self face“,

⁹<https://openbci.com/>

teda tváre cudzích alebo známych osôb. Prezentovanie podnetov prebieha v určitých postupnostiach, ktoré sú dané počtom podnetov typu „non-self face“, po ktorých nasleduje podnet typu „self face“. Pre zabezpečenie takejto prezentácie podnetov je potrebné generovať náhodné číslo od 1 do 4, ku ktorému sa vždy pripočíta posun, čo tvorí rozdiel takto vygenerovaného čísla z predchádzajúcej postupnosti podnetov a čísla 4. Takto vzniknutá hodnota predstavuje počet zobrazovaných podnetov cudzích alebo známych osôb, po ktorých nasleduje zobrazenie tváre užívateľa. Pri prezentovaní prvej postupnosti podnetov je hodnota posunu nastavená na nulu. Zvolenie počtu stimulov na hodnotu 50 som testovaním vyhodnotil ako vhodný kompromis medzi zvládnuteľnou časovou náročnosťou vykonania jednotlivých procesov aplikácie a presnosťou klasifikačných modelov preberaných v sekcii 4.5.

Počas stimulácie mozgu užívateľa sa zaznamenávajú typy jednotlivých podnetov a to „0“ pre cudzie tváre a „1“ pre tvár užívateľa. Tieto hodnoty spolu so zaznamenanými EEG signálmi slúžia k trénovaniu klasifikátorov.

Následujúci výpis kódu 4.2 predstavuje zabezpečenie náhodnosti prezentácie podnetov.

```
import random

...

pause_offset = 0

# STIMULI_NUM is the number of stimuli
if self_face_count < round(STIMULI_NUM * 0.2):
    if pause_sequence == 0:
        pause_sequence = random.randint(1, 4)

    if non_self_face_count < (pause_sequence + pause_offset):
        non_self_face_count += 1
        stimuli_types = np.append(stimuli_types, 0)
        # non-self face image
        return set_non_self_face_stimulus()
    else:
        self_face_count += 1
        non_self_face_count = 0
        pause_offset = 4 - pause_sequence
        pause_sequence = 0
        stimuli_types = np.append(stimuli_types, 1)
        # self face image
        return set_self_face_stimulus()
else:
    stimuli_types = np.append(stimuli_types, 0)
    # non-self face image
    return set_non_self_face_stimulus()

...
```

Výpis 4.2: Prezentácia náhodných podnetov.

Stimulácia mozgu užívateľa pri procese identifikácie je trochu odlišná. V tomto procese sa vopred neurčuje počet stimulov, ale tento počet vychádza z počtu registrovaných užívateľov. V tejto metóde stimulácie sa načítajú všetky podnety a identifikačné prihlasovacie údaje registrovaných užívateľov a vytvorí sa z nich vektory. Tieto vektory slúžia na zobrazenie podnetov z fotografií tvárí týchto registrovaných užívateľov a namiesto označení typu podnetov ako „0“ a „1“ sa využívajú označenia príslušných prihlasovacích údajov k

predstavovaným podnetom. Vytvorený vektor podnetov sa po jeho prezentácii náhodne zamieša čím sa zabezpečí náhodnosť prezentovaných podnetov. Výpis 4.3 predstavuje spôsob prezentácie podnetov pri procese identifikácie užívateľa.

```
...

if identification_count > -1:
    if id_array_count == len(identification_pixmaps):
        id_array_count = 0
        c = list(zip(identification_pixmaps,
                    pixmaps_ids))
        random.shuffle(c)
        identification_pixmaps, pixmaps_ids = zip(*c)

    identification_count -= 1
    id_array_count += 1
    stimuli_types = np.append(stimuli_types, pixmaps_ids[id_array_count - 1])
    return identification_pixmaps[id_array_count - 1]

...
```

Výpis 4.3: Prezentácia náhodných podnetov v procese identifikácie.

4.4 Spracovanie charakteristík EEG signálov

Pri spracovaní charakteristík EEG signálov je potrebné najskôr tieto signály očistiť od nežiadúcich artefaktov a frekvencií, ktoré sú detailne preberané v kapitole 2, sekcii 2.3. Pri čistení signálov som využil metódy navrhnuté v kapitole 3 a to pásmovú prepust', ktorá odstraňuje frekvencie medzi 50 a 60 Hz a odstránenie šumu zo signálu pomocou prahovania koeficientov vlnkovej transformácie. Použitie týchto metód predstavuje výpis kódu 4.4.

```
from brainflow import DataFilter, FilterTypes, AggOperations

...

for i in range(16):
    DataFilter.perform_bandstop(self.data[i], 256, 55.0, 10.0, 3,
                                FilterTypes.BUTTERWORTH.value, 0)

    DataFilter.perform_wavelet_denoising(self.data[i], 'db6', 3)

...
```

Výpis 4.4: Filtrácia nežiadúcich artefaktov a frekvencií zo zaznamenaného signálu.

Po vyčistení signálov je potrebné tieto signály rozdeliť na dĺžkou totožné časové bloky. Ako je spomenuté v kapitole 3, tak významnými kanálmi pre vzor „self face & non-self face“ sú kanály F3, F4, C3 a C4. Tieto kanály najefektívnejšie zaznamenávajú zmeny mozgovej aktivity pri spomínanom vzore. Dĺžku časových okien som určil na 800 ms, aby obsahovali všetky potrebné komponenty (spomenuté v kapitole 3), ktoré sú vykazované pri použitom vzore. Počet vzniknutých časových blokov je totožný s počtom prezentovaných stimulov a každý blok predstavuje reakciu na príslušný podnet. Výpis kódu 4.5 predstavuje takéto spracovanie EEG signálov.

```

import numpy as np

...

for i in range(num_of_stimuli):
    stimuli_time_ms = stimuli_timestamps[i] * 1000

    F3 = np.array([])
    F4 = np.array([])
    C3 = np.array([])
    C4 = np.array([])

    for y in range(len(timestamps)):
        eeg_timestamp_ms = timestamps[y] * 1000
        # num_of_x is the number of signal samples that represent 800 ms
        if eeg_timestamp_ms >= stimuli_time_ms and len(F3) < num_of_x:
            F3 = np.append(F3, data[10, y])
            F4 = np.append(F4, data[11, y])
            C3 = np.append(C3, data[2, y])
            C4 = np.append(C4, data[3, y])

    epoch = np.array([F3, F4, C3, C4])
    stimuli_epochs.append(epoch)

...

```

Výpis 4.5: Rozdelenie signálu na časové bloky.

Takto vytvorené časové bloky, ktoré predstavujú jednotlivé reakcie na prezentované podnety sa uložia do objektu užívateľa. Tento objekt sa následne uloží do internej zložky aplikácie označenej `db` pomocou knižnice `pickle`¹⁰ a jeho dáta sa využívajú v procese prihlásenia.

4.5 Klasifikácia a riadenie systému

Ako je spomenuté v úvode tejto kapitoly, implementácia klasifikačných metód je dôležitá pre splnenie kritéria o presnosti a spoľahlivosti systému. Pri klasifikácii som sa rozhodol využiť a vyhodnotiť metódy lineárnej diskriminačnej analýzy a konvolučnej neurónovej siete. Tieto metódy sú bližšie rozobrané v kapitole 2, sekcii 2.4.

Lineárna diskriminačná analýza

Dáta je potrebné pred vstupom do klasifikačnej metódy upraviť. V tomto kroku je nutné vykonať normalizáciu hodnôt jednotlivých reakcií a to pomocou knižnice `sklearn`, ktorá je spomenutá v úvode tejto kapitoly. Z takto normalizovaných dát sa následne vypočítajú priemerne hodnoty signálu. Pre túto úpravu som sa rozhodol na základe vykonávaných testov predstavených v kapitole 5. Následujúci výpis kódu 4.6 predstavuje takúto úpravu.

```

from sklearn import preprocessing

...

for i in range(len(input_data)):

```

¹⁰<https://docs.python.org/3/library/pickle.html>

```

epoch = []
norm_data_0 = preprocessing.normalize(np.array([input_data[i][0]]))
norm_data_1 = preprocessing.normalize(np.array([input_data[i][1]]))
norm_data_2 = preprocessing.normalize(np.array([input_data[i][2]]))
norm_data_3 = preprocessing.normalize(np.array([input_data[i][3]]))
avg = (norm_data_0 + norm_data_1 + norm_data_2 + norm_data_3) / 4
epoch = avg[0]
fit_data.append(epoch)

```

Výpis 4.6: Úprava vstupných tréningových dát lineárnej diskriminačnej analýzy.

Samotná tvorba modelu sa taktiež upravovala postupným vykonávaním testov predstavených v kapitole 5. Podľa vykonaných testov pre lineárnu diskriminačnú analýzu vyšla ako najpresnejšia metóda riešenia problému metóda najmenších štvorcov označená ako `lsqr`. Presnejší popis tejto metódy poskytuje kapitola 2, sekcia 2.4. Výpis kódu 4.7 predstavuje vytvorenie modelu LDA, jeho tréningovanie a klasifikáciu neznámych vstupných dát.

```

from sklearn.discriminant_analysis import LinearDiscriminantAnalysis
...

model = LinearDiscriminantAnalysis(solver='lsqr', shrinkage=0.924)
model.fit(fit_data, fit_data_types)
result = model.predict(predict_data)
...

```

Výpis 4.7: Tvorba, tréningovanie a predikcia modelu lineárnej diskriminačnej analýzy.

Konvolučná neurónová sieť

Pri konvolučnej neurónovej sieti je taktiež potrebné upraviť vstupné dáta a to normalizáciou rovnakým spôsobom ako je popísané v časti o lineárnej diskriminačnej analýze.

Konvolučnú neurónovú sieť som na základe testov preberaných v kapitole 5 zostavil z 10 vrstiev. Týchto desať vrstiev pozostáva z dvoch konvolučných vrstiev a po každej z nich nasleduje jedna združovacia vrstva. Presnejší popis činnosti týchto dvoch typov vrstiev preberá kapitola 2, sekcia 2.4. Piata vrstva je typu „flatten“ a slúži na sploštenie vstupu a jeho transformáciu na 1D. Po tejto vrstve nasleduje plne prepojená vrstva typu „dense“. Siedma vrstva je označená ako „batch_normalization“ a slúži pre normalizáciu svojich vstupov. Ďalšou vrstvou je vrstva typu „dropout“, ktorá slúži pre vynechanie niektorých hodnôt na vstupe tejto vrstvy, čo slúži pre zvýšenie presnosti pri predikcii nových dát. Finálne dve vrstvy sú plne prepojené typu „dense“. Všetky parametre predstavených vrstiev som určil na základe testov predstavených v kapitole 5.

Celé schéma zostavenej konvolučnej neurónovej sieti predstavuje výpis 4.8 a jej implementáciu, tréningovanie a predikciu predstavuje výpis kódu 4.9.

```

Model: "CNN"
-----
Layer (type)                Output Shape          Param #
-----
conv2d (Conv2D)             (None, 4, 200, 32)    320
-----
max_pooling2d (MaxPooling2D) (None, 4, 197, 32)    0
-----
conv2d_1 (Conv2D)           (None, 4, 197, 64)    18496
-----

```

| | | |
|------------------------------|--------------------|----------|
| max_pooling2d_1 (MaxPooling2 | (None, 4, 194, 64) | 0 |
| flatten (Flatten) | (None, 49664) | 0 |
| dense (Dense) | (None, 500) | 24832500 |
| batch_normalization (BatchNo | (None, 500) | 2000 |
| dropout (Dropout) | (None, 500) | 0 |
| dense_1 (Dense) | (None, 100) | 50100 |
| dense_2 (Dense) | (None, 2) | 202 |
| ===== | | |
| Total params: 24,903,618 | | |
| Trainable params: 24,902,618 | | |
| Non-trainable params: 1,000 | | |
| ===== | | |

Výpis 4.8: Schéma vytvorenej konvolučnej neurónovej siete.

```

from tensorflow.keras import layers, models

...

model_cnn = models.Sequential([
    layers.Conv2D(filters=32, kernel_size=(3, 3), activation='relu', padding='same',
        input_shape=(4, num_of_x, 1), use_bias=True),
    layers.MaxPooling2D(pool_size=(1, 4), strides=1),
    layers.Conv2D(filters=64, kernel_size=(3, 3), activation='relu', padding='same',
        use_bias=True),
    layers.MaxPooling2D(pool_size=(1, 4), strides=1),
    layers.Flatten(),
    layers.Dense(units=500, activation='relu'),
    layers.BatchNormalization(),
    layers.Dropout(0.2),
    layers.Dense(units=100, activation='relu'),
    layers.Dense(units=2, activation='softmax'),
])

model.compile(optimizer=Adam(learning_rate=0.002), loss='sparse_categorical_crossentropy',
    metrics=['accuracy'])

model_cnn.fit(x=training_samples, y=training_data_types, batch_size=10, epochs=30,
    verbose=2, shuffle=True)

result = model.predict(x=predicting_samples, batch_size=1, verbose=0)

```

Výpis 4.9: Implementácia CNN, jej tréovanie a predikcia.

Riadenie systému

Výstup klasifikačných metód je vo forme stanovenia typov vstupných reakcií a to „1“ pre reakcie na tvár užívateľa a „0“ pre reakcie na tváre cudzích alebo známych osôb. V procese prihlásenia sa následne takto získané predikcie porovnávajú s reálnymi typmi prezentovaných podnetov, kedy užívateľ musí potvrdiť svoju totožnosť správnymi reakciami na väčšinu prezentovaných podnetov.

V procese identifikácie je riadenie systému odlišné. Pri vyhodnocovaní tohto procesu sa sledujú predikcie klasifikačných metód, kedy sa hľadá maximálny počet pozitívnych reakcií na prezentované podnety. Táto maximálna hodnota pozitívnych reakcií následne určuje identitu prístupujúceho užívateľa.

Kapitola 5

Testovanie a vyhodnotenie funkcionality systému

Správna funkcionality systému, ktorý identifikuje a verifikuje osoby s využitím EEG je závislá na všetkých krokoch predstavených v kapitole 3. Najkritickejším bodom je klasifikácia charakteristík EEG signálu, ktoré predstavujú reakciu užívateľa na prezentované podnety. V tejto kapitole sa preberá metodika vykonávaných testov, ktorá je predstavená v sekcii 5.1. Vyhodnotenie výsledkov vykonaných testov predkladá sekcia 5.2.


5.1 Metodika a výsledky testovania

Kľúčovou metrikou, ktorú je potrebné sledovať pri testovaní je presnosť klasifikačnej metódy. Testovanie prebiehalo z dôvodu epidemiologických opatrení na jednej zdravej osobe vo veku 22 rokov. Subjekt bol pravák s normálnou kontrolou nad vizuálnym vnemom a nikdy sa u neho nevyskytli neurologické alebo psychiatrické poruchy. Proces testovania prebiehal opakovaným vykonávaním možných procesov aplikácie a to registrácie, prihlásenia a identifikácie. Za celú dobu tvorby práce sa vykonali štyri takéto testovania s dvojtýždňovými rozstupmi. Počas každého testovania sa taktiež vytvárali súbory s dátami pre testovanie bez potreby zariadenia. Tieto dáta pozostávali z nameraných hodnôt EEG signálov, časových záznamov jednotlivých hodnôt, časových záznamov prezentovaných stimulov a z ich počtu a typov. S takto vytvorenými dátovými súbormi je možné replikovať celý postup aplikácie od bodu zaznamenávania pod bod klasifikácie a riadenia systému predstavenými v kapitole 3.

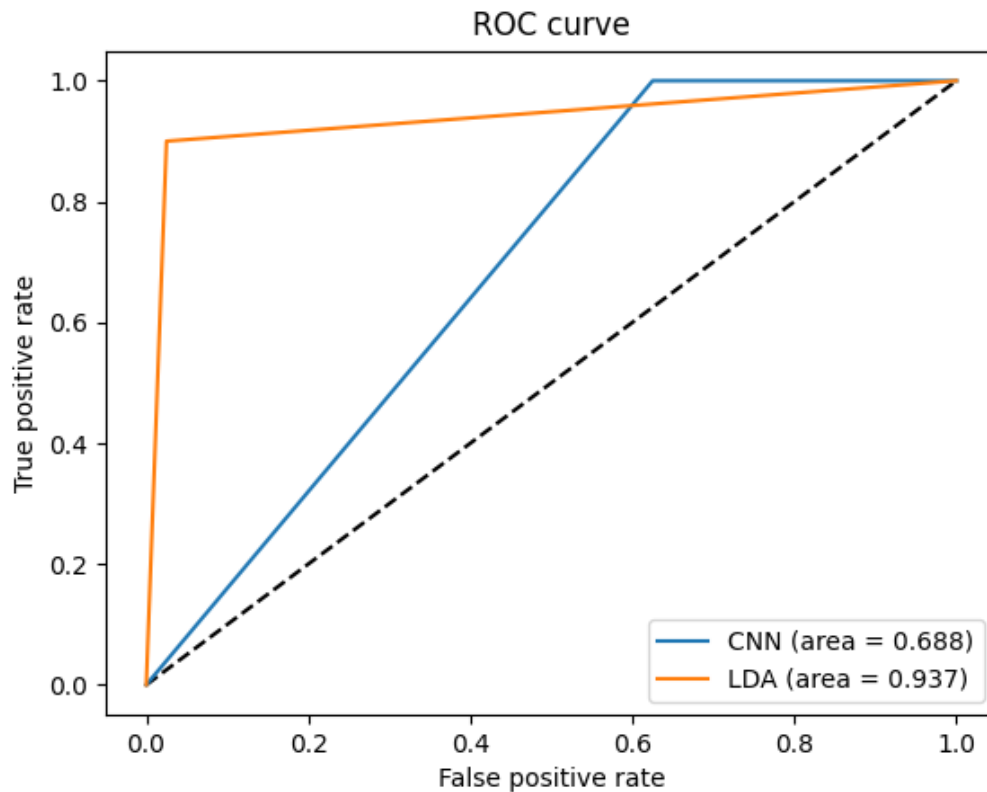
Prvotné testovania slúžili pre určenie najvhodnejších parametrov klasifikačných metód a spôsobu úpravy dát vstupujúcich do týchto metód. Po úspešnom definovaní parametrov a skladby klasifikačných modelov prebehlo testovanie ich úspešnosti na spomenutých dátových súboroch. Vyhodnotenie úspešnosti klasifikačných metód prebiehalo pomocou krivky AUC-ROC. Táto krivka slúži pre vizualizáciu výkonu klasifikačných metód a je to jednou z najviac využívaných techník pre vyhodnotenie správnosti klasifikačných modelov [18]. Časť ROC predstavuje krivku pravdepodobnosti a AUC predstavuje stupeň miery oddeliteľnosti hodnôt. Táto metóda vyhodnotenia vypovedá o tom, ako veľmi je model schopný rozlišovať medzi klasifikovanými triedami. Čím väčšia je hodnota AUC, tým presnejší je model pri predpovedaní jednotlivých tried.

Testovanie úspešnosti klasifikačných metód prebiehalo na 42 zvolených dátových súboroch. Toto testovanie spočívalo vo výbere dvoch náhodných dátových súborov, kde dáta

jedného súboru predstavovali tréningové dáta klasifikačnej metódy a dáta druhého súboru slúžili k predikcii ich tried. Takýto náhodný výber sa zopakoval 10000-krát, čo malo vynahradiť testovanie s veľkým počtom užívateľov. Graf 5.1 predstavuje výsledky testovania priemernej presnosti klasifikačných metód LDA a CNN pomocou AUC-ROC krivky, kde sa dosiahli presnosti 66,2 % pri lineárnej diskriminačnej analýze a 58,7 % pri konvolučnej neurónovej sieti. Maximálnymi dosiahnutými presnosťami sú 93,7 % pri lineárnej diskriminačnej analýze a 68,8 % pri konvolučnej neurónovej sieti. Maximálne dosiahnuté presnosti predstavuje graf 5.2.



Obr. 5.1: Priemerne hodnoty ROC-AUC krivky pri presnosti klasifikačných metód. Lineárna diskriminačná analýza s priemernou presnosťou 66,2 % a konvolučná neurónová sieť s priemernou presnosťou 58,7 %.



Obr. 5.2: Maximálne hodnoty ROC-AUC krivky pri presnosti klasifikačných metód. Lineárna diskriminačná analýza s maximálnou presnosťou 93,7 % a konvolučná neurónová sieť s maximálnou presnosťou 68,8 %.

Po testovaní presností klasifikačných metód nasledovala celková simulácia riadenia systému pomocou spomenutých dátových súborov. V tomto procese prebehlo 1681 opakovaní registrácie a prihlásenia do systému, kedy sa sledovala úspešnosť procesu prihlásenia. Z týchto simulácií vzišlo 560 úspešných prihlásení z celkového počtu 1681, čo predstavuje približne 33 % úspešnosť.

Proces identifikácie užívateľa bol testovaný iba s využitím EEG zariadenia kedy dochádzalo k postupnému pridávaniu nových užívateľov a tým zvyšovaniu náročností tohto procesu. Z celkového počtu 52 testov bolo 42 úspešných, čo predstavuje 80,8 % úspešnosť tohto procesu.

5.2 Vyhodnotenie funkcionality systému

Na základe získaných výsledkov predstavených v sekcii 5.1 usudzujem, že systém dokáže splňovať svoju funkciu iba v niektorých prípadoch. To znamená, že užívateľ musí vo väčšine prípadov proces riadenia systému opakovať. Úspešnosť verifikácie užívateľa je z výsledkov pomerne nízka a užívateľ bude musieť tento proces opakovať aby získal požadovaný výsledok. V procese identifikácie užívateľa sa dosiahla pomerne vysoká úspešnosť a to vďaka nižším nárokom na samotné vyhodnotenie výsledkov klasifikačných metód, kedy sa sleduje maximálny počet pozitívne ohodnotených reakcií.

Z využitých klasifikačných metód sa ako najpresnejšia osvedčila metóda lineárnej diskriminačnej analýzy, ktorá síce ako priemernú presnosť dosiahla len 66,2 %, ale jej maximálna presnosť dosiahla vynikajúcu hodnotu, a to 93,7 %. Takýto výsledok nasvedčuje tomu, že pri veľmi priaznivých podmienkach, kedy je užívateľ plne sústredený a pri sledovaní predstavovaných podnetov vykonáva počítanie zobrazení jeho vlastnej tváre, je implementovaný systém funkčný. Implementovaná konvolučná neurónová sieť vyšla z vykonaných testov ako podpriemerná a nepostačujúca k riešeniu zadaného problému.

Dôvodom takýchto výsledkov testovania môže byť kumulatívna chyba, ktorej tvorba začína pri spôsobe zaznamenávania EEG signálov a končí pri samotnej klasifikačnej metóde. Využitie suchých elektród môže predstavovať prvý faktor negatívneho ovplyvnenia kvality signálov, kedy je potrebné, aby zariadenie dokázalo zaznamenať nie len komponentu P300, ale aj zložitejšie komponenty, ako je N270 a N150 (predstavené v kapitole 2, sekcii 2.5). Ďalší potenciálny problém vidím v procese prezentácie podnetov užívateľovi, kedy by mohla nastať situácia, že užívateľ reaguje na celkovú kompozíciu fotografie a nie na predstavovanú tvár.

Kapitola 6

Záver

Cieľom tejto práce bolo navrhnuť, implementovať a otestovať systém, ktorý identifikuje a verifikuje osoby s využitím elektroencefalografie. Koncept tohto systému je založený na individuálnosti reakcií užívateľa na fotografie jeho vlastnej tváre a fotografií tvári cudzích alebo známych osôb.

K vytvoreniu takéhoto systému boli predstavené princípy práce s EEG signálmi a rozhraním medzi mozgom a počítačom, v čom spočíva zaznamenávanie mozgovej aktivity, stimulácii mozgu užívateľa, filtrácii zaznamenaných signálov, klasifikácii reakcií užívateľa a interpretácii výsledkov klasifikácie. Dôležitým faktorom pre splnenie tohto cieľa bol správne určený postup krokov a metód, ktoré viedli k spoľahlivému, presnému a užívateľsky prívetivému systému. Po rozdelení problému na jednotlivé kroky a určení vhodných metód riešenia bola implementovaná aplikácia, prostredníctvom ktorej boli vykonávané experimenty za cieľom overenia funkcionality systému.

Testovanie z dôvodu pandemických opatrení prebiehalo na jednej osobe a to formou viacerých sedení, kedy sa taktiež vytvárali dátové súbory pre testovanie bez nutnosti využitia elektroencefalografického zariadenia. Pri testovaní lineárnej diskriminačnej analýzy bola priemerná presnosť metódy 66,2 % a maximálna dosiahnutá presnosť bola 93,7 %. Následne prebehlo testovanie konvolučnej neurónovej siete, ktorej priemerná presnosť bola 58,7 % a maximálnu presnosť dosiahla 68,8 %. Systém s takýmito presnosťami klasifikačných metód je funkčný, ale jeho užívatelia musia vo vysokom počte prípadov opakovať jednotlivé operácie systému. Dôvodom takýchto hodnôt môže byť kumulatívna chyba, ktorá začína pri spôsobe zaznamenávania mozgovej aktivity a končí pri samotných klasifikačných metódach. Najpravdepodobnejšie chybové kroky sú spôsob zaznamenávania mozgovej aktivity, kedy zaznamenávacie zariadenie nesprostredkováva presné hodnoty a krok prezentovania podnetov užívateľovi, kde je možné že nastane moment, kde užívateľ nereaguje na prezentovanú tvár ale na celkovú kompozíciu fotografie.

Pri ďalšom vývoji tejto práce sa dá pokračovať testovaním viacerých zariadení pre zaznamenávanie mozgovej aktivity a určením najpresnejšej metódy tohto kroku. Ďalšou možnosťou je spresniť spôsob spracovávania fotografií tvári užívateľov a ich prezentáciu, aby sa predišlo možným reakciám na celkovú kompozíciu predstavovaného podnetu.

Literatúra

- [1] *Brain-Computer Interface Research: A State-of-the-Art Summary 5*. Cham: Springer International Publishing, 2017. SpringerBriefs in Electrical and Computer Engineering. ISBN 978-3-319-57131-7.
- [2] ABIRI, R., BORHANI, S., SELLERS, E. W., JIANG, Y. a ZHAO, X. A comprehensive review of eeg-based brain–computer interface paradigms. *Journal of Neural Engineering*. 2019, zv. 16, č. 1, s. 011001. ISSN 1741-2560.
- [3] AL SAFFAR, A. A. M., TAO, H. a TALAB, M. A. Review of deep convolution neural network in image classification. In: *2017 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET)*. IEEE, 2017, 2018-, s. 26–31. ISBN 9781538638491.
- [4] BOBROV, P., FROLOV, A., CANTOR, C., FEDULOVA, I., BAKHNYAN, M. et al. Brain-Computer Interface Based on Generation of Visual Images. eScholarship, University of California. 2011. Dostupné z: <https://escholarship.org/uc/item/4g96q2bd>.
- [5] CHAISAEN, R., AUTTHASAN, P., MINGCHINDA, N., LEELAARPORN, P., KUNASETH, N. et al. Decoding EEG Rhythms During Action Observation, Motor Imagery, and Execution for Standing and Sitting. *IEEE sensors journal*. IEEE. 2020, zv. 20, č. 22, s. 13776–13786. ISSN 1530-437X.
- [6] COHEN, M. X. Where Does EEG Come From and What Does It Mean? *Trends in neurosciences (Regular ed.)*. Elsevier Ltd. 2017, zv. 40, č. 4, s. 208–218. ISSN 0166-2236.
- [7] EBERMAM, E. a KROHLING, R. A Comprehensive Introduction to Neural Convolutional Networks: A Case Study for Character Recognition. *Sistemas de Informação (Macaé)*. Faculdade Salesiana Maria Auxiliadora. 2018, zv. 1, č. 22, s. 49–59. ISSN 1983-5604. Dostupné z: <https://doaj.org/article/dc52e18de5534e669c7d295503407b3a>.
- [8] EDWARDS, J., WENG, J., BESOLD, T., PERLOVSKY, L. a ROY, A. *Representation in the Brain*. Frontiers Media SA, 2018. ISBN 9782889455966.
- [9] GAO, Z., DANG, W., LIU, M., GUO, W., MA, K. et al. Classification of EEG Signals on VEP-Based BCI Systems With Broad Learning. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. 2020, s. 1–9. ISSN 2168-2216.

- [10] GUI, Q., RUIZ BLONDET, M., LASZLO, S. a JIN, Z. A survey on brain biometrics. *ACM Computing Surveys*. Association for Computing Machinery. 2019, zv. 51, č. 6. ISSN 03600300.
- [11] JIANG, X., BIAN, G. a TIAN, Z. Removal of Artifacts from EEG Signals: A Review. *Sensors*. MDPI. 2019, zv. 19, č. 5. ISSN 1424-8220.
- [12] KAPPENMAN, E. a LUCK, S. *The Oxford Handbook of Event-Related Potential Components*. Január 2012. 1-664 s.
- [13] KUMAR, J. S. a BHUVANESWARI, P. Analysis of Electroencephalography (EEG) Signals and Its Categorization—A Study. *Procedia engineering*. Elsevier Ltd. 2012, zv. 38, s. 2525–2536. ISSN 1877-7058.
- [14] LI, F., LI, X., WANG, F., ZHANG, D., XIA, Y. et al. A Novel P300 Classification Algorithm Based on a Principal Component Analysis-Convolutional Neural Network. *Applied sciences*. MDPI AG. 2020, zv. 10, č. 4, s. 1546. ISSN 2076-3417. Dostupné z: <https://doaj.org/article/f8dd9d55c88f405185fe78f7e0803ed9>.
- [15] MAMUN, M., AL KADI, M. a MARUFUZZAMAN, M. Effectiveness of Wavelet Denoising on Electroencephalogram Signals. *Journal of applied research and technology*. Elsevier España, S.L.U. 2013, zv. 11, č. 1, s. 156–160. ISSN 1665-6423.
- [16] MOHAMMED, M., KHAN, M. B. a BASHIER, E. B. M. Linear Discriminant Analysis. In: *Machine Learning: Algorithms and Applications*. CRC Press, 2017, s. 129–136. ISBN 9781498705387.
- [17] NARDELLI, P. a HANDROOS, H. Review of the State-of-the-art on Bio-signal-based Brain-controlled Vehicles. *ArXiv.org*. Ithaca: Cornell University Library, arXiv.org. 2020. ISSN 2331-8422. Dostupné z: <http://search.proquest.com/docview/2409768180/>.
- [18] NARKHEDE, S. Understanding auc-roc curve. *Towards Data Science*. 2018, zv. 26, s. 220–227.
- [19] O'SHEA, K. a NASH, R. An Introduction to Convolutional Neural Networks. *ArXiv.org*. Ithaca: Cornell University Library, arXiv.org. 2015. ISSN 2331-8422. Dostupné z: <http://search.proquest.com/docview/2083864399/>.
- [20] PARK, C. H. a PARK, H. A comparison of generalized linear discriminant analysis algorithms. *Pattern recognition*. Elsevier Ltd. 2008, zv. 41, č. 3, s. 1083–1097. ISSN 0031-3203.
- [21] PFURTSCHELLER, G. a NEUPER, C. Motor imagery activates primary sensorimotor area in humans. *Neuroscience letters*. Elsevier Ireland Ltd. 1997, zv. 239, 2-3, s. 65–68. ISSN 0304-3940.
- [22] RAMADAN, R. A. a VASILAKOS, A. V. Brain computer interface: control signals review. *Neurocomputing (Amsterdam)*. Elsevier B.V. 2017, zv. 223, s. 26–44. ISSN 0925-2312.
- [23] RAMSEY, N. F. *Brain-Computer Interfaces*. 2020. Issn Ser. ISBN 9780444639332.

- [24] SAZGAR, M. M. a YOUNG, M. Absolute Epilepsy and EEG Rotation Review. In: *Springer International Publishing*. 2019.
- [25] SEECK, M., KOESSLER, L., BAST, T., LEIJTEN, F., MICHEL, C. et al. The standardized EEG electrode array of the IFCN. *Clinical neurophysiology*. Elsevier B.V. 2017, zv. 128, č. 10, s. 2070–2077. ISSN 1388-2457.
- [26] SIULY, S., LI, Y. a ZHANG, Y. *EEG Signal Analysis and Classification: Techniques and Applications*. Cham: Springer International Publishing, 2017. Health Information Science. ISBN 978-3-319-47652-0.
- [27] VAŘEKA, L. Evaluation of convolutional neural networks using a large multi-subject P300 dataset. *Biomedical signal processing and control*. Elsevier Ltd. 2020, zv. 58. ISSN 1746-8094.
- [28] VEGA ESCOBAR, L., CASTRO OSPINA, A. E. a DUQUE MUNOZ, L. Feature extraction schemes for BCI systems. In: *2015 20th Symposium on Signal Processing, Images and Computer Vision (STSIVA)*. IEEE, 2015, s. 1–6. ISBN 9781467394611.
- [29] WEN, D., LI, P., LI, X., WEI, Z., ZHOU, Y. et al. The feature extraction of resting-state EEG signal from amnesic mild cognitive impairment with type 2 diabetes mellitus based on feature-fusion multispectral image method. *Neural networks*. Elsevier Ltd. 2020, zv. 124, s. 373–382. ISSN 0893-6080.
- [30] WOLPAW, J. a WOLPAW, E. *Brain-Computer Interfaces: Principles and Practice*. Oxford University Press, USA, 2012. ISBN 9780195388855. Dostupné z: https://books.google.sk/books?id=tC2Uzuc_WBQC.
- [31] YASODA, K., PONMAGAL, R. S., BHUVANESHWARI, K. S. a VENKATACHALAM, K. Automatic detection and classification of EEG artifacts using fuzzy kernel SVM and wavelet ICA (WICA).(Report). *Soft Computing - A Fusion of Foundations, Methodologies and Applications*. Springer. 2020, zv. 24, č. 21, s. 16011. ISSN 1432-7643.
- [32] YEOM, S.-K., SUK, H.-I. a LEE, S.-W. Person authentication from neural activity of face-specific visual self-representation. *Pattern recognition*. Elsevier Ltd. 2013, zv. 46, č. 4, s. 1159–1169. ISSN 0031-3203.
- [33] ÖZKARA, B. An introduction to the event-related potential technique. *Tüketici ve Tüketim Araştırmaları Dergisi = Journal of Consumer and Consumption Research*. Istanbul: Beta Basım Yayın Dağıtım. 2019, zv. 11, č. 2, s. 437–441. ISSN 13096362. Dostupné z: <http://search.proquest.com/docview/2415469318/>.

Zoznam príloh

| | |
|---------------------------------|-----------|
| A Obsah pamäťového média | 46 |
| B Plagát | 47 |

Príloha A

Obsah pamäťového média

Na priloženom pamäťovom médiu sa nachádzajú tieto súbory:

- **aplikácia** – Zložka obsahuje zdrojové súbory systému, ktorý identifikuje a verifikuje osoby s využitím EEG.
- **aplikácia\ nas** – Obsahuje README súbor s návodom na inštaláciu a spustenie.
- **doc** – Zložka obsahuje dokumentáciu zdrojového kódu pomocou nástroja **sphinx**.
- **latex** – Zložka obsahuje zdrojové súbory pre vytvorenie tohto dokumentu.
- **pdf** – Zložka obsahuje výsledný dokument **pdf**.
- **plagát** – Zložka obsahuje plagát.
- **video** – Zložka obsahuje demonštračné video.

Príloha B

Plagát



NAS
NEURAL ACCESS SYSTEM

VUT - VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

Identifikace a verifikace osob s využitím EEG

Roland Žitný, vedoucí práce Ing. Jan Tinka

EEG
Zaznamenávanie reakcií užívateľa na prezentované podnety vo forme fotiek tvári



Spracovanie signálov
Odstránenie nežiadúcich artefaktov a vytvorenie časových okien, ktoré predstavujú jednotlivé reakcie užívateľa



Bandpass Wavelet



Klasifikácia
Vytvorené časové bloky sa následne predajú klasifikačnej metóde pre určenie typu reakcie



LDA CNN



Vyhodnotenie
Vyhodnotenie klasifikovaných reakcií a oboznámenie užívateľa o výsledku procesu



Motivácia

- Predstavenie novej metódy zabezpečenia
- Odstránenie rizika vystavenia prístupových údajov okoliu

Koncept

- Koncept systému je založený na unikátnosti mozgových vln pri reakciách na tvár seba samého a tváre iných ľudí