

Západočeská univerzita v Plzni
Fakulta aplikovaných věd
Katedra informatiky a výpočetní techniky

Bakalářská práce

Detekce EEG artefaktů s využitím hlubokého učení

Místo této strany bude
zadání práce.

Prohlášení

Prohlašuji, že jsem bakalářskou práci vypracovala samostatně a výhradně s použitím citovaných pramenů.

V Plzni dne 27. června 2018

Aneta Medunová

Poděkování

Ráda bych poděkovala Ing. Lukášovi Vařekovi za odborné vedení, trpělivost a ochotu, kterou mi v průběhu zpracování bakalářské práce věnoval.

Abstract

The aim of this bachelor thesis is design of a simple assistive system based on the detection of eye blink in the EEG data. Moreover, implementation and testing of the proposed system is described. The thesis contains an overview of electroencephalography and related signal processing. It also includes a basic overview and information about BCI systems. LDA classifier and neural networks were implemented and their results are compared and evaluated.

Abstrakt

Cílem této bakalářské práce je návrh jednoduchého asistenčního systému založeného na detekci mrkání v EEG záznamu, dále implementace a otestování jeho částí. Práce obsahuje přehled o elektroencefalografii, způsobech měření EEG dat, nežádoucích artefaktech a důležité předzpracování dat. Součástí je i základní přehled a informace o BCI systémech. Je zde provedena implementace LDA klasifikátoru a neuronových sítí, jejich výsledky jsou porovnány a zhodnoceny.

Obsah

1	Úvod	1
2	Teoretická část	2
2.1	Elektrické biosignály lidského těla	2
2.1.1	Způsoby měření dat z mozku	2
2.2	Elektroencefalografie (EEG)	3
2.2.1	Historie EEG	3
2.2.2	Popis metody	3
2.2.3	Elektrody	4
2.2.4	Zesilovač	6
2.3	Frekvenční pásma	6
2.3.1	Evokované potenciály (EP)	7
2.3.2	Rozdělení podle druhu stimulace	8
2.4	Artefakty	9
2.4.1	Artefakt mrkání	11
2.5	Asistenční systémy	11
2.5.1	Brain - computer interface	11
2.5.1.1	Princip	11
2.5.1.2	Způsoby využití BCI	12
2.5.1.3	Historie BCI	13
2.5.1.4	Základní komponenty BCI systému	13
2.5.2	Asistenční systém založený na mrkání	14
2.5.2.1	Základní komponenty	14
2.6	Předzpracování	15
2.7	Klasifikace	17
2.7.1	Lineární klasifikátory	17
2.7.1.1	Lineární diskriminační analýza - LDA	17
2.7.2	Neuronové sítě	18
2.7.2.1	Biologický neuron	18
2.7.2.2	Umělá neuronová síť	19
2.7.2.3	Rozdělení umělých neuronových sítí	21
2.7.2.4	Deep learning (Hluboké učení)	21
3	Realizační část	23
3.1	Získání dat	23
3.1.1	Postup měření	23

3.2	Vstupní data	26
3.3	Formát vstupních dat	27
3.4	Předzpracování	27
3.4.1	Filtrace	27
3.4.2	Segmentování do epoch	29
3.4.3	Extrakce příznaků	31
3.5	Realizace algoritmů	31
3.5.1	LDA	31
3.5.2	Neuronové sítě	32
3.6	Využité technologie	34
3.6.1	Jazyk a nástroje	34
3.6.2	Přehled funkcí v programu	35
4	Dosažené výsledky testování	38
4.1	Výsledky klasifikací	38
4.1.1	Zhodnocení výsledků jednotlivých subjektů	40
4.1.2	Celkové zhodnocení	43
5	Závěr	44
	Literatura	49
A	Přílohy	51
A.1	Obsah CD	51
A.2	Uživatelská dokumentace	52

1 Úvod

Mnoho lidí vlivem různých úrazů nebo poruch nemůže plně komunikovat se světem, neboť jsou upoutáni na lůžko. Pro takové osoby je asistenční systém přínosný, jelikož jim může velice usnadnit životní situaci. Samotný pojem asistenční systém lze chápat různými způsoby, existuje široká škála lidských omezení, která nelze řešit jedním způsobem. Například osoba, která má ochrnuté tělo, ale plně funkční mozek, může s vhodným asistenčním systémem být částečně osvobozena od plné závislosti na druhých.

Brain-computer interface (BCI) je rozhraní mezi mozkiem a počítačem. Toto spojení pomáhá lidem ovládat různá zařízení, například robotické končetiny nebo jiné přístroje, pouze pomocí myšlenek. Nejčastěji využívaným způsobem získávání elektroencefalografických (EEG) dat je neinvazivní metoda měření, při níž je biosignál snímán přes velice špatně vodivou lebku. Takový signál je nutné snímat se zesilovačem a obsahuje velké množství nežádoucích šumů, takzvaných artefaktů.

Ve své práci jsem se zaměřila na již zmíněné artefakty, které bývají v signálu většinou nechtěnými. Jinak nežádoucí artefakty mohou být užitečné, jsou-li využívány jako potvrzování záměru uživatele (například rozsvícení světla). Jejich výhodou je podstatně vyšší amplituda, než amplituda vyvolaná myšlenkou, proto se snáze klasifikují. Takový systém už není BCI, protože není založený na mozkovém signálu, ale na svalové aktivitě okohybných svalů. Jedná se o obecný asistenční systém.

Asistenční systém, který budu vytvářet bude rozpoznávat potřebu uživatele. V náhodném pořadí se na obrazovce budou zobrazovat různé obrázky (například jídlo, lampa apod.), které reprezentují několik potřeb člověka. Měřená osoba mrkne vždy, když chtěnou potřebu uvidí na obrázku. Po naměření jsou data předána klasifikátoru, který je vyhodnotí a zobrazí výsledek klasifikace.

V teoretické části jsou vysvětleny základní principy a metody měření a klasifikace. Po teorii následuje realizace části asistenčního systému, k jejíž implementaci jsem zvolila neuronové sítě a lineární diskriminační analýzu (LDA). Závěrem porovnám a zhodnotím výsledky těchto klasifikací.

2 Teoretická část

2.1 Elektrické biosignály lidského těla

Elektrické signály v našem těle generují svalové a nervové buňky a jsou výsledkem elektrochemických procesů mezi těmito buňkami a uvnitř nich. Tyto biosignály slouží v lékařství k vyjádření informací o sledovaném organismu. Existuje několik druhů vyšetření v závislosti na zkoumané oblasti (Obr. 2.1). [3]

Biosignál	Napěťový rozsah	Frekvenční rozsah	Testovací napětí
Elektrokardiogram EKG – srdce	0,5–5 mV	0,05–100Hz	1 mV
Elektroencefalogram EEG – mozek	2–200 μ V	0,5–200 Hz	50 μ V
Elektromyogram EMG – svaly	0,05–5 mV	2–500 Hz	-
Elektrookulogram EOG – oko	10 μ V–3,5 mV	0–100Hz	-

Obrázek 2.1: Typické hodnoty vybraných elektrických biosignálů u člověka. (Zdroj: [17])

2.1.1 Způsoby měření dat z mozku

Při měření dat mozkové aktivity rozlišujeme celkem tři druhy systémů. Jejich rozdělení závisí na tom, jakým způsobem zavádíme snímače. [15]

Invazivní systémy

Jedná se o nejpřesnější měření mozkové aktivity, při níž se senzory zavádí přímo do šedé kůry mozkové pomocí neurochirurgického zákroku. Získané signály jsou v nejvyšší možné kvalitě. Nevýhodou invazivních systémů je náchylnost k rozšiřování zjizvené tkáně, což může mít za následek zeslabení nebo úplnou ztrátu signálu. [15]

Částečně invazivní systémy

Tento systém je rozdělen na dvě části. Jedna část je implementována přímo do šedé kůry mozkové, druhá se nachází mimo organismus. Tento typ nese pozitivní vlastnosti invazivní i neinvazivní metody. [15]

Neinvazivní systémy

Neinvazivní systém není implantován do mozku, ale nachází se celý mimo organismus. Elektromagnetické vlny aktivity mozku jsou zaznamenávány skrze kůži i lebku. Výhodou této metody je jednoduchost, protože nepotřebuje žádný chirurgický zákrok. Velkou nevýhodou je omezená citlivost. Jedná se většinou o různé nasazovací čepice s citlivými senzory. [15]

2.2 Elektroencefalografie (EEG)

Elektroencefalografie je základní elektrofyziologická neinvazivní metoda, která zaznamenává aktuální elektrickou aktivitu mozku. Jedná se o složitý elektrický biosignál, jež odráží mozkovou aktivitu. Mozkové vlny jsou součástí elektromagnetického pole, které vzniká kolem mozku díky elektrické aktivitě neuronů. EEG aktivita prodělává velké změny za fyziologických a patologických podmínek, protože je odrazem funkčních stavů mozku. Její změny jsou patrné v závislosti na věku, bdělosti, otevření či zavření očí anebo jiné zevní stimulaci. Záznam časové změny elektrického potenciálu způsobené mozkovou aktivitou nazýváme elektroencefalogram. Tato metoda má všestranné využití v řadě oborů. Zejména v neurologii při diagnostice záchvatovitých stavů (epilepsie), v neurochirurgii při kontrolách po operacích nebo v psychiatrii a jiných. [3]


2.2.1 Historie EEG

První zprávy o produkci elektrických fenoménů živou tkání pocházejí z 18. století. V polovině 19. století byla německým lékařem a fyziologem Emilem du Bois - Reymondem vyvinuta nepolarizovatelná elektroda ke snímání elektrické aktivity žabího srdce. Ve 2. polovině 19. století popsal britský fyziolog Richard Caton elektrické aktivity králíčích a opičích mozků. V roce 1924 zaznamenal německý psychiatr Hans Berger první EEG záznam lidského mozku. Koncem 30. let 20. století vznikají první jednoúčelová zařízení pro EEG záznamy. V 60. a 70. letech 20. století došlo k rozvoji přístrojové techniky. [5, 6, 10]

2.2.2 Popis metody

Jedná se o neinvazivní metodu, což znamená, že jsou snímací elektrody umístěny na povrchu hlavy, takzvané skalpové EEG. Problémem je, že průcho-

dem přes relativně málo vodivou lebku je amplituda signálu zeslabena na úroveň řádově desítek mikrovoltů. Na povrch lebky rozmístíme elektrody, které slouží jako propojení mezi vodivou tekutinou ve tkáních a vstupem zesilovače. Rozmístění elektrod je pevně stanovené, jedná se o systém zvaný 10/20 (Obr. 2.3). Měření standardně probíhá v klidovém stavu. Měřená osoba sedí nebo leží a na hlavě má upevněnou speciální čepici, na které jsou elektrody pevně rozmístěny tímto systémem. Systém 10/20 je meziná-



Obrázek 2.2: Rozmístění elektrod systémem 10-20.

(Zdroj: <https://www.dreamstime.com/stock-photos-eeeg-electrode-placement-image29444803>)

rodně uznávaný systém pro rozmístění elektrod. Je založen na vztahu mezi pozicemi elektrod a pod nimi ležící mozkovou kůrou. Každá elektroda je označena písmenem a číslicí (Obr. 2.3). Písmena označují předozadní lokalizaci podle oblastí (Obr. 2.4).

Fp – frontopolární	F – frontální
P – parietální	C – centrální
T – temporální	O – okcipitální

Lichá čísla jsou v levé hemisféře, sudá jsou v pravé hemisféře.

2.2.3 Elektrody

Zajišťují převod bioelektrické aktivity mozku do zesilovače. Jejich konstrukce se dělí podle využití. Elektrod existuje mnoho druhů, primárně lze rozdělit

do tří kategorií.

Podpvrchové

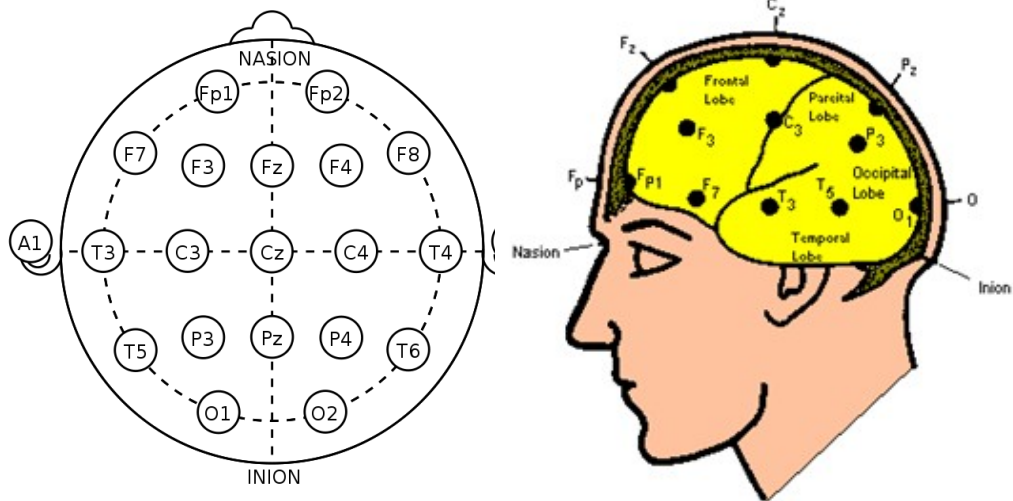
Vpichují se pod pokožku v celé své délce.

Pvrchové

Přikládají se na očištěnou pokožku. Elektroda je namazána elektrovedivou pastou.

Mikroelektrody

Speciální elektrody, které jsou zkonstruované například pro měření buněčného potenciálu jediného neuronu.



Obrázek 2.3: Označení elektrod. (Zdroj: <https://www.wikiskripta.eu/w/Elektroencefalografie>)

Obrázek 2.4: Rozdělení mozkových oblastí. (Zdroj: <http://1000projects.org/brain-computer-interface-seminar.html>)

2.2.4 Zesilovač

Protože mají elektrické potenciály snímané elektrodami velmi nízkou amplitudu, je nutné napětí nejprve zesílit, aby bylo možné jej dále zpracovávat. Jednou z možností je připojení vstupního diferenčního zesilovače. Diferenční zesilovač má dva vstupy, jeden přímý (aktivní) a druhý invertovaný (referenční). Tento zesilovač pracuje tak, že zesílí napěťový rozdíl mezi oběma vstupy. Jeden smysl tohoto zapojení je v tom, že pokud bude na obou vstupech přiveden signál od elektrod a naindukují se na ně stejně velké rušivé napětí, pak se toto napětí vzájemně odečte a na výstupu se neprojeví.

2.3 Frekvenční pásma

Delta

Pro tyto vlny jsou charakteristické frekvence v rozmezí 0,5 – 4 Hz (Obr. 2.5). U dospělých se běžně nacházejí při hluboké meditaci a NREM spánku. Dále je možné tyto vlny nalézt u dětí. [20]

Theta

Theta vlny se vyskytují při frekvencích 4 – 8 Hz (Obr. 2.5). Aktivace těchto vln nastává v některých fázích spánku, při meditaci nebo hluboké relaxaci. [20]

Alfa


Pro tyto vlny je charakteristická frekvence 8 – 13 Hz (Obr. 2.5). U zdravých dospělých se vyskytují v bdělém stavu, při zavřených očích a během relaxace. [20]

Beta

Beta vlny se vyskytují při frekvencích 13 – 30 Hz (Obr. 2.5). Typicky v bdělém stavu, hlavně frontálně. Jsou patrné při rozumovém uvažování. [20]

Gama

Vlny s frekvencí 30 Hz a více. Toto pásmo není tolik prozkoumáno, spojuje se v souvislosti s hlubokou koncentrací. [20]



Obrázek 2.5: Mozkové vlny
(Zdroj [20])

2.3.1 Evokované potenciály (EP)

Evokované potenciály jsou významné změny bioelektrické aktivity mozku vyvolané nějakým vnějším stimulem. Tyto specifické odpovědi nazýváme evokované potenciály (ERP event-related potentials). Současně se stimulem se do signálu musí vkládat značka, které definuje čas vzniku konkrétního stimulu, aby bylo možné později vyhodnocovat záznam. EP patří k pomocným vyšetřovacím metodám v neurologii.

ERP představují krátkodobé vlny s nízkou amplitudou, jejichž morfologie (tvar, latence, délka) závisí na síle stimulu a rovněž na momentálním mentálním stavu měřené osoby, jakým může být například míra únavy, stres a podobně. [7]

Exogenní EP

Tyto potenciály závisí na smyslové oblasti. Představují odezvy na uměle navozené stimuly. Doba latence je nízká.


Endogenní

Závisí na momentálním psychickém stavu měřené osoby. Měřený subjekt myslí na určitou věc. Není nutné používat stimuly, nicméně v některých případech mohou zlepšit zkoumání signálu. Jedná se například o pohyb kurzoru po obrazovce pouze pomocí myšlenek. Souvisí s kognitivním procesem. Doba latence endogenních EP je delší než 300 ms.

2.3.2 Rozdělení podle druhu stimulace

Sluchové EP

Stimuluje se obvykle krátkým pípnutím o určité frekvenci. Odezvou je série vln, která určuje jakým způsobem se neuroinformace šíří od sluchového nervu v uchu do mozkové kůry. Elektrody umísťujeme za levé a pravé ucho a na vrchol hlavy (Obr. 2.6).



Obrázek 2.6: Měření sluchového EP.

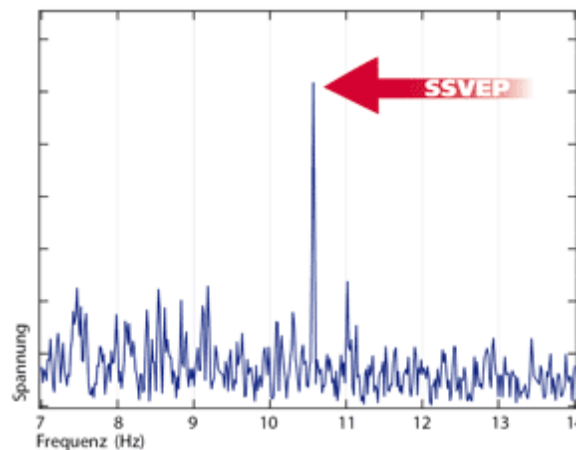
(Zdroj: <https://medium.com/@mindpass2050/the-stimulus-reaction-challenge-d86cd57e22fe>)

Zrakové VEP

Jedná se o reakci mozku na určité stimuly. Stimulace probíhá většinou pomocí série nějakých obrázků nebo blikajících světél. Elektrody se umístí v týlní oblasti hlavy.

SSVEP (Steady state visually evoked potential)

Ustálené vizuální evokované potenciály, jsou speciálním případem vizuálních evokovaných potenciálů. Jedná se o reakci mozku vyvolanou vizuální stimulací. Stimulace se provádí jako blikání obrazců na obrazovce při konstantní frekvenci v rozmezí přibližně 6 Hz – 100 Hz. Když je sítnice drážděna takovou stimulací, reakce se projeví jako zvýšení amplitudy stimulované frekvence (Obr. 2.7). [18]



Obrázek 2.7: Frekvenční spektrum mozkových signálů se SSVEP amplitudou při stimulační frekvenci 10,5Hz.

(Zdroj: http://www.emg.tu-bs.de/forschung/ceeg/ssvep_e.html)

2.4 Artefakty


Za artefakt je považován nežádoucí signál transponovaný na EEG záznam. Má původ jinde, než ve zkoumané oblasti. Artefakty rozlišujeme na biologické a technické. [1]

Technické artefakty

Jsou vázány především na zpracování, různá rušení nebo specifika jednotlivých metod (Obr. 2.8). Tyto artefakty mohou vznikat na základě interference se zdroji elektrické energie nebo jiného elektromagnetického pole v blízkosti EEG přístroje. Nejčastější příčinou bývají rozdíly impedancí elektrod. Záznam mohou ovlivnit i artefakty z jiných přístrojů s jinou frekvencí, jež se

nacházejí v blízkosti měřícího EEG přístroje. Například mobilní telefony, ventilace apod. [1]

- Síťový artefakt
- Šum přístroje
- Síťový brum
- Elektrostatické artefakty
- Elektrostatické potenciály



Obrázek 2.8: Ukázka projevů několika technických artefaktů v naměřeném signálu.

(Zdroj: <http://www.zbynekmlcoch.cz/informace/medicina/neurologie-nemoci-vysetreni/artefakty-na-eeg-zaznamu-obrazky-deleni-eeg-artefaktu>)

Biologické artefakty

Souvisí s projevem organismu měřeného subjektu. Některé artefakty může měřená osoba ovlivnit, některé pocházejí ze základní funkční činnosti organismu a nelze je ovlivnit (Obr. 2.9). [1]

- Srdeční aktivita
- Pohyb očí
- Svalová aktivita




Obrázek 2.9: Ukázka projevů několika biologických artefaktů v naměřeném signálu.

(Zdroj: <http://www.zbynekmlcoch.cz/informace/medicina/neurologie-nemoci-vysetreni/artefakty-na-eeg-zaznamu-obrazky-deleni-eeg-artefaktu>)

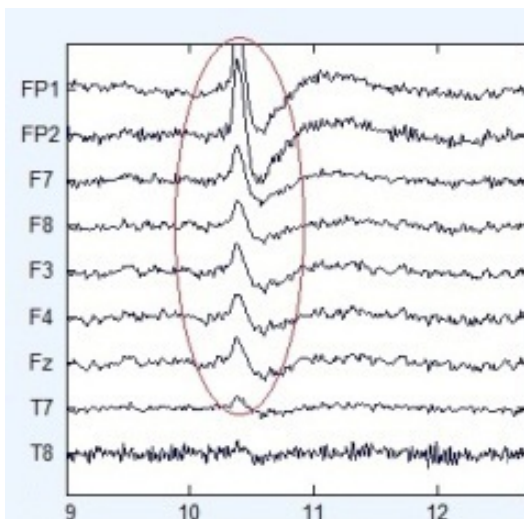
2.4.1 Artefakt mrkání

Při mrknutí oka je provedena svalová aktivita okoohybných svalů (Obr. 2.10), která se projeví v EEG signálu (Obr. 2.11). Za standardních okolností je tento projev nazýván artefaktem a bývá v signálu nežádoucím.



Obrázek 2.10: Svaly oka.

(Zdroj: <http://www.nabla.cz/obsah/biologie/kapitoly/biologie-cloveka/svaly-hlavy-musculi-capitis.php>)



Obrázek 2.11: Ukázka mrknutí v signálu

(Zdroj: http://www.stepwards.com/?page_id=8632)

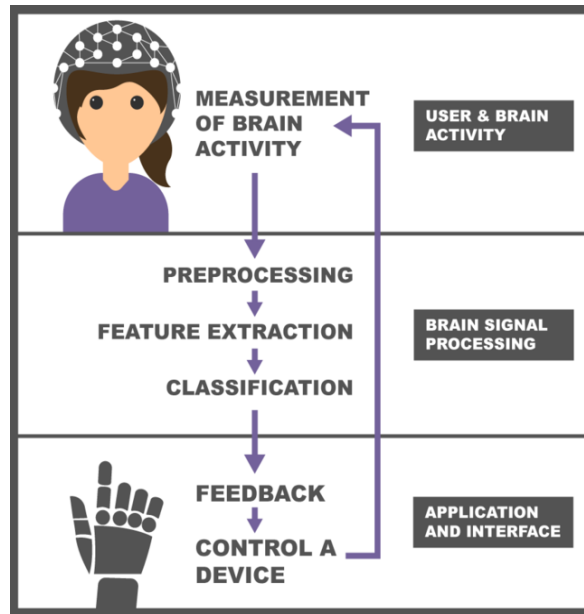
2.5 Asistenční systémy

2.5.1 Brain - computer interface (BCI)

Systém, který obchází obvyklé výstupní kanály mozku. Vznikl, aby bylo umožněno lidem, kteří z nějakého důvodu nemohou ovládat své výstupní tělesné periferie, pohodlněji komunikovat se světem. Například pro svalově ochrnuté jedince ovládat různá robotická zařízení pouze pomocí mozku apod.

2.5.1.1 Princip

BCI systémy slouží jako pojitko spolupráce mezi mozkiem a jiným zařízením (Obr. 2.12). Převádí mozkovou aktivitu na signály vhodné k dalšímu využití.



Obrázek 2.12: Architektura BCI systému.
 (Zdroj: <https://www.futurelearn.com/courses/robotic-future/0/steps/26359>)

2.5.1.2 Způsoby využití BCI

Pomocná vyšetřovací metoda.

Pomocí BCI systému lze v medicíně monitorovat a detekovat abnormální mozkovou aktivitu, například některé druhy nádorového onemocnění, neobvyklé záchvatovité chování, kterým se projevuje epilepsie, dále detekce určitých spánkových poruch, migrén a dalších.[21]

Řešení tělesných omezení

Robotické protézy pro pacienty, kteří mají určité omezení mobility.

Vzdělávání

Vzdělávací systémy zabývající se určením stupně porozumění studované informace na základě elektrické aktivity mozku. [22]

2.5.1.3 Historie BCI

První velký průlom nastal v roce 1969, kde Eberhard E. Fetz s kolegy poprvé ukázali, že opice dokáží pomocí neuronové aktivity mozku ovládat pohyblivé elektrické rameno. Dále docházelo v tomto oboru k rychlému rozvoji. [11]

2.5.1.4 Základní komponenty BCI systému

Jednotlivé komponenty jsou zobrazeny (Obr. 2.12), ze kterého vycházejí níže uvedené body.

Měření aktivity mozku - V této části jsou získávána data z mozku. Aktivitu mozku lze měřit pomocí různých metod. V praxi je nejvíce využívána neinvazivní EEG metoda.

Separace artefaktů

Tato jednotka snižuje šum a artefakty přítomné v signálu.

Extrakce vlastností

Transformuje předzpracované signály na hodnoty, které odpovídají základnímu neurologickému mechanismu.

Klasifikace

Tato část provádí identifikaci záměru uživatele z extrahovaných funkcí.

Ovládání zařízení

Výstup klasifikátoru se používá jako příkaz k ovládání výstupního zařízení. Výstupním zařízením může být počítač, invalidní vozík nebo robotické rameno atd.

Zpětná vazba

Reakce systému na mozkovou aktivitu uživatele, díky níž může uživatel zdokonalovat spolupráci se systémem. Může být ve vizuální, sluchové nebo hmatové podobě.

2.5.2 Asistenční systém založený na mrkání

Již zmíněné BCI systémy jsou založeny na detekci mozkové aktivity a její rozpoznávání. Asistenční systém, narozdíl od BCI, není založen na mozkovém signálu, ale na detekci svalové aktivity záměrně vyvolaných okohybných svalů, projevující se v EEG datech jako artefakt (Kapitola 2.4.1). Ve článku [23] je návrh obdobného systému zrealizován. Při vytváření asistenčního systému se nejprve naměří EEG data, která budou obsahovat záměrně vyvolané artefakty mrknutí při konkrétním stimulu. Data jsou předána systému, aby se podle nich mohl učit. Ten je nejprve předzpracuje a následně předá klasifikátoru. Při předzpracování dat se vytvářejí segmenty v takovém rozsahu, aby bylo příkladné mrknutí do segmentu zahrnuto. Je-li klasifikátor naučený, můžeme mu poskytnout stejným způsobem upravená data určená ke klasifikaci.

2.5.2.1 Základní komponenty

Měření EEG

V této části jsou získávána data z mozku. Nejčastějším způsobem bývá neinvazivní metoda.

Předzpracování

Použití filtru k odstranění některých nežádoucích šumů v signálu a segmentace do epoch.

Extrakce vlastností

Transformuje předzpracované signály na hodnoty, které odpovídají základnímu neurologickému mechanismu.

Klasifikace

Tato část provádí identifikaci záměru uživatele z extrahovaných funkcí.

Ovládání zařízení

Výstup klasifikátoru se používá jako příkaz k ovládání výstupního zařízení. Výstupním zařízením mohou být různé přístroje napomáhající lidem.

Zpětná vazba

Reakce systému na mozkovou aktivitu uživatele, díky níž může uživatel zdokonalovat spolupráci se systémem.

2.6 Předzpracování

Signál, který naměříme obsahuje velké množství šumů a jiných artefaktů, proto používáme filtry, které mají za úkol oddělit signál od artefaktů a zvýraznit určité složky mozkové aktivity.

Dolní propust


Jedná se o frekvenčně lineární filtr, který nepropouští signál vyšších frekvencí.

Horní propust


Jedná se o frekvenčně lineární filtr, který nepropouští signál nižších frekvencí.

Průměrování

Průměrování je jednou z nejpoužívanějších metod předzpracování vstupních dat. Naměřený signál nejprve segmentujeme do takzvaných epoch. Epoque je oblast v okolí synchronizační značky, která udává výskyt určité události (zobrazení konkrétního stimulu). Epochu lze vyčlenit například 0.5s před značkou a 1s po výskytu značky. V další fázi epochy zprůměrujeme a tím se potlačí zkladní EEG aktivita, která se v jednotlivých epochách chová jako náhodný signál.



Obrázek 2.13: Segmentace na jednotlivé epochy
 (Zdroj: www.kiv.zcu.cz/studies/predmety/uir/predn/P6/Neuroinformatika.pps)



Obrázek 2.14: Průměrování jednotlivých epoch
 (Zdroj: [16])

2.7 Klasifikace

Klasifikace je jednou ze základních úloh strojového učení. Existují dvě nebo více tříd, do kterých se data třídí na základě pozorování a ohodnocení. Aby bylo možné data správně vyhodnocovat, je zapotřebí dodat klasifikátoru připravenou trénovací množinu dat, kde je kategorie předem určena. Na základě trénování klasifikátor vyhodnocuje schody testovacích dat s trénovacími a třídí je do kategorií. Takovou klasifikaci nazýváme učení s učitelem. Další možností je učení bez učitele, při kterém nemáme žádná trénovací data. Úkolem je data popsat určením závislostí.

2.7.1 Lineární klasifikátory

Obecně je klasifikátor matematický model, kterých ve strojovém učení existuje několik druhů, ale lineární klasifikátory se řadí k nejjednodušším a velmi populárním. Jejich výhodou je především jednoduchost a výpočetní nenáročnost. Lineární klasifikátor hledá nejvhodnější přímku nebo obecně nadrovinu, aby rozdělil příznakový prostor podle klasifikačních tříd.

2.7.1.1 Lineární diskriminační analýza - LDA

Je založena na konceptu hledání lineární kombinace proměnných, které nejlépe oddělují dvě třídy dat.

Bayesovské rozhodovací pravidlo

Toto pravidlo minimalizuje celkovou pravděpodobnost mylné klasifikace.

Odvození Bayesovského rozhodovacího pravidla

V [4] je Bayesovské rozhodovací pravidlo definováno: "Nechť v 1. skupině je n_1 objektů, ve 2. skupině n_2 objektů. Každý objekt je charakterizován p -rozměrným vektorem pozorování $X = (X_1, \dots, X_p)$. Předpokládáme, že v h -té skupině má náhodný vektor X hustotu $\varphi_h(x)$, $h = 1, 2$. Nechť H_h je jev "objekt patří do h -té skupiny". Apriorní pravděpodobnost $P(H_h)$ příslušnosti objektu k h -té skupině označíme π_h , $h = 1, 2$. Známe-li u nějakého objektu vektor pozorování x , můžeme podle Bayesova vzorce vypočítat aposteriorní pravděpodobnost příslušnosti objektu ke skupině: "

$$P(H_h / X = x) = \frac{\pi_h \varphi_h(x)}{\pi_1 \varphi_1(x) + \pi_2 \varphi_2(x)}, \quad h = 1, 2$$

Objekt je zařazen do skupiny 1, je-li $\pi_1\varphi_1(x) > \pi_2\varphi_2(x)$, v opačném případě spadá do skupiny druhé. Součin $\pi_h\varphi_h(x)$ se nazývá diskriminační skór pro h-tou skupinu. [4]

2.7.2 Neuronové sítě


Jedním z hlavních důvodů rozvoje umělých neuronových sítí byl zájem člověka prozkoumat funkci lidského mozku. Vlastnosti mozku tvoří podklady k tvorbě teorií pro umělé neuronové sítě, proto je vhodné se nejprve seznámit se základní funkcí lidského mozku. [14, 24]

2.7.2.1 Biologický neuron

Biologický neuron je základním stavebním prvkem centrálního nervového systému. Tato buňka se specializuje na přenos, zpracování a uchování informace. Lidský mozek obsahuje přibližně 50-100 miliard neuronových buněk. Existuje jich několik druhů a jsou navzájem propojeny do velmi složitých neuronových sítí. [14, 24]

Z pohledu zpracování a uchování informací jsou důležité tyto části neuronu:

- Soma - tělo biologického neuronu o velikosti jen několik mikrometrů.
- Dendrity - výběžky vyčníhající ze somy, je jich řádově několik tisíc. Jsou to vstupní přenosové kanály.
- Axon - přenáší informace zpracované v těle buňky do dalších neuronů pomocí jejich synaptických spojení. Jeho délka může nabývat až 60cm.
- Výstupy (Synapse) - Rozvětvení konce axonu. Jedná se o unikátní mezineuronové rozhraní, spojující s dendrity jiných neuronů a tím tvoří spojení mezi neurony. Během života neustále vznikají nové synaptické spoje.




Obrázek 2.15: Struktura biologického neuronu
 Zdroj: <http://statnice.e-misa.info/C2-01.pdf>

2.7.2.2 Umělá neuronová síť

Umělá neuronová síť je jedním z výpočetních modelů, které využívá umělá inteligence. Základem tohoto modelu je umělý (nebo také formální) neuron (Obr. 2.16), který simuluje chování biologického neuronu. [14] **Umělý neuron**

Na vstupu neuronu je vektor $X[x_1, x_2, \dots, x_n]$ a váhový vektor $W[w_1, w_2, \dots, w_n]$, který ohodnocuje vstupní synapse, přivádějící vstupy do těla neuronu. V těle neuronu se porovnáním váhových a sečtených vstupů s prahem získává vnitřní potenciál ξ . Za tělem následuje blok aktivační přenosové funkce $\sigma\{\xi\}$, provádějící nelineární transformaci vnitřních potenciálů na jednu hodnotu, tedy $R^n \rightarrow R$. Posledním je výstup y . Vnitřní potenciál je možné vyjádřit zápisem $\xi = \sum_{i=1}^n w_i x_i - h$, kde n je počet vstupů neuronu, x jsou samotné vstupy, w vyjadřuje váhové koeficienty a h je prahová hodnota aktivace neuronu. [14]




Obrázek 2.16: Umělý neuron
(Zdroj: [14])

Architektura umělé neuronové sítě

Umělá neuronová síť představuje topologické uspořádání jednotlivých neuronů do struktury komunikující pomocí orientovaných ohodnocených spojů [14]. Nejčastěji používané jsou dopředné neuronové sítě. Jejich signál se sítí šíří od vstupu jednosměrně směrem k výstupům sítě. Obecně ji můžeme rozdělit na tři části (Obr. 2.17): [9, 14]

- Vstupní vrstva - tvoří ji n vstupních neuronů distribuujících do další vrstvy vstupní signály x_1, \dots, x_n [24].
- Skrytá vrstva - jedna nebo více vrstev, které se nacházejí mezi vstupní a výstupní vrstvou.
- Výstupní vrstva - poslední vrstva neuronové sítě.

V dopředné neuronové síti každá jednotka, neuron, pracuje samostatně. Taková síť je značně robustní a odolává poškození. Obvykle dokáže i při poškození některých elementů poskytovat relevantní výstupy [14].



Obrázek 2.17: Vícevrstvá neuronová síť.
(Zdroj: [14])

2.7.2.3 Rozdělení umělých neuronových sítí podle charakteru učení

Adaptační algoritmy při hledání řešení postupují podobně jako člověk. Hledají řešení, která jsou podobná již známým příkladům. Nastavení vah neuronu tedy odpovídá nalezení co nejvýstižnější transformace na základě známých hodnot s předpokladem, že nalezená transformace bude dostatečně obecná i pro další neznámé příklady dané domény, byť tomu tak být nemusí [14].

Tyto algoritmy rozdělujeme do dvou oblastí: [14]

- **Učení bez učitele** - Takový algoritmus nemá předem známé žádné kritérium správnosti. Síť dostává pouze sadu vzorů, které dále třídí do různých skupin. Hledá elementy, které jsou si „podobné“.
- **Učení s učitelem** - Algoritmus dostane množinu trénovacích dat X_n a jejich příslušná ohodnocení y_n . Na základě těchto příkladů se učí.

2.7.2.4 Deep learning (Hluboké učení)

Deep learning je forma strojového učení, které umožňuje počítačům učit se ze zkušeností. Tato oblast umělé inteligence se začala rozvíjet teprve před několika lety. V minulosti nebyl rozvoj deep learningu možný z důvodu nedostatečné znalosti efektivních algoritmů a nedostatečné výpočetní síly. Deep

learning využívají právě neuronové sítě. Označení deep vystihuje podstatu vrstvení do hloubky. Termínem deep neural network můžeme označit všechny neuronové sítě, které mají jednu a více skrytých vrstev. [12]

Oproti jednodušším algoritmům disponuje hluboká neuronová síť vyšší spolehlivostí při klasifikaci, dokáže rozpoznávat objekty i člověka.

Přetrénování neuronové sítě

Tento stav může nastat v případě *učení bez učitele*, kdy se síť nachází ve stavu, ve kterém rozpoznává vstupy s dostatečnou spolehlivostí. Při dalším trénování se může síť dostat do stavu přetrénování. Takový stav znamená, že charakteristické rysy nejsou obecné, ale příliš odpovídají trénovací sadě, což se projevuje zvýšenou chybovostí. [12]

3 Realizační část

Cílem této práce bylo navrhnout jednoduchý asistenční systém, který bude detekovat mrkání v již zaznamenaných EEG signálech (tzn. off-line). Hlavním realizačním výstupem byla implementace částí systému týkajících se neuronových sítí a otestování implementovaného algoritmu na reálných datech. Dále provést implementaci i jiného algoritmu a porovnat výsledky s výsledky neuronových sítí.

Uvažovala jsem nad implementací v programovacím jazyce Java nebo Python. V Javě je již na Katedře informatiky a výpočetní techniky (KIV) vyvíjen projekt umožňující klasifikaci EEG záznamů. Nevýhodou je omezená podpora neuronových sítí a méně pohodlné rozhraní pro jejich návrh a testování. Po zvážení byl zvolen jazyk Python, který je poměrně dobře vybaven knihovnamí MNE [13], Scikit-learn [19], Keras [8] a dalšími, pro snadnější práci s neurofyziologickými daty.

3.1 Získání dat

Data byla získána v laboratoři neuroinformatiky, kde je veškeré potřebné vybavení pro měření EEG signálů. Postupně jsem provedla měření na dvanácti osobách různého pohlaví i věkové kategorie. Zde je možné využít speciální temnou komoru k navození ideálních podmínek, jakými jsou ticho a tma, a následné získání kvalitnějších dat. Pro tento projekt byla ovšem potřeba získat taková data, která se nejlépe přibližují realitě. Z tohoto důvodu jsem zvolila použití mobilního zesilovače a měření u stolu v laboratoři, kde se pohybovaly i jiné osoby a občas byl trochu ruch.


3.1.1 Postup měření

Administrativa

Před měřením byl každý subjekt požádán o umytí vlasů (stačilo večer před), aby odpor mezi pokožkou a elektrodou byl co nejmenší. Po příchodu do laboratoře jsem vždy měřeného nejprve seznámila s postupem, kterým budu měření provádět a dále ho požádala o podepsání souhlasu s naměřením a uchováním dat.

Příprava subjektu

Nejprve je nutné měřené osobě odmastit čelo a ušní lalok abrazivním gelem. Důkladné očištění výrazně ovlivňuje snížení odporu. Po očištění se nanese vodivá pasta na referenční elektrodu a za pomoci lepící pásky připevní nad kořen nosu, stejným postupem zemníci elektroda na ušní lalok. Dále se nasadí EEG čepice a za pomoci injekční stříkačky s tupou jehlou se nanáší EEG vodivý gel do elektrod rozmístěných systémem 10/20. Pro naměření signálu z mrkání není nutné používat všechny elektrody, dostačující je využití pouze níže vyznačených elektrod (Obr. 3.1), které byly zvoleny osově symetricky pro obě oči a s různou vzdáleností od očí, aby bylo možné vyhodnotit přítomnost nebo nepřítomnost artefaktu mrkání..



Obrázek 3.1: Implementované elektrody.

(Zdroj: <https://www.wikiskripta.eu/w/Elektroencefalografie>)

Průběh měření

Před zahájením si subjekt vybral jeden z devíti nabízených obrázků, které reprezentují několik lidských potřeb, jakými jsou:


Otevření dveří	Rozsvícení světla
Potřeba toalety	Hlad
Zavolat si	Pustit televizi
Pomoc	Pustit rádio
Otevřít okno	

Měření probíhalo ve dvou fázích. První bylo měření se stimulačním scénářem, kde se náhodně promítalo devět stimulů, každý byl zobrazen celkem pětkrát (Obr. 3.3). Toto měření mělo celkem tři opakování, mezi nimiž měl subjekt vždy prostor se napít a uvolnit, aby se při zaznamenávání cítil co nejlépe.

Druhá fáze probíhala obdobně, pouze stimulační scénář byl v jiném formátu. Namísto jednotlivých obrázků byla promítána matice, jejíž řádky a sloupce se náhodně rozsvícili tak, aby byl každý obrázek v rozsvíceném pruhu celkem desetkrát (Obr. 3.2). Toto měření mělo dvě opakování.



Obrázek 3.2: Printscreen stimulace 2. měření.



Obrázek 3.3: Příklad časového grafu zobrazení stimulu pro tři opakování. Rozložení bylo generováno náhodně, pro každé měření bylo jiné.

Po měření

Po ukončení stimulace je nutné pečlivě zaznamenat metadata o průběhu, aby bylo následné zpracování dat co nejpřesnější.

3.2 Vstupní data

Vstupní data byla získána naměřením EEG signálu popsáném v předchozí kapitole 3.1. Měření probíhalo celkem na pěti elektrodách Fp1, Fp2, Fz, Cz, Pz, které se v naměřených datech vyznačují jako channel 1 - channel 5. Paralelně se s měřeným signálem zaznamenávala i informace o vyvolání stimulu v podobě jeho indexu. Naměřená data jsem rozdělila do dvou skupin, jedna skupina dat byla vybrána pro klasifikaci a druhá skupina na trénování sítí.

3.3 Formát vstupních dat


Data jsou uložena v několika souborech:

- **soubor.vhdr** - Hlavičkový soubor, obsahující informace o měřených kanálech, jejich impedancích v [kOhm] a odkazy na další soubory s daty. Tento soubor je načítán programem jako vstupní.
- **soubor.vmrk** - Takzvaný „MarkerFile“, uchovává informaci o přiřazení stimulu k jednotlivým datům.
- **soubor.eeg** - Datový soubor s naměřenými daty.
- **soubor.avg** - Průměrné napětí epoch.


3.4 Předzpracování

3.4.1 Filtrace

Filtrování načteného signálu je vhodný způsob pro odstranění některých šumů a nežádoucích artefaktů v signálu. Na obrázku (Obr. 3.4) je zobrazena část načtených dat, na která nebyl aplikován žádný filtr. Na obrázku (Obr. 3.5) je na stejná data aplikován filtr, který znatelně sníží výskyt některých šumů a nežádoucích artefaktů. Na základě literatury [16] a z několika prováděných experimentů jsem vyvodila závěr, že nejvhodnější použití pro filtraci tohoto signálu je nastavení filtru: horní propust - 0.1 Hz a dolní propust - 30 Hz.



Obrázek 3.4: Signál před aplikací filtru.




Obrázek 3.5: Signál po aplikaci filtru.

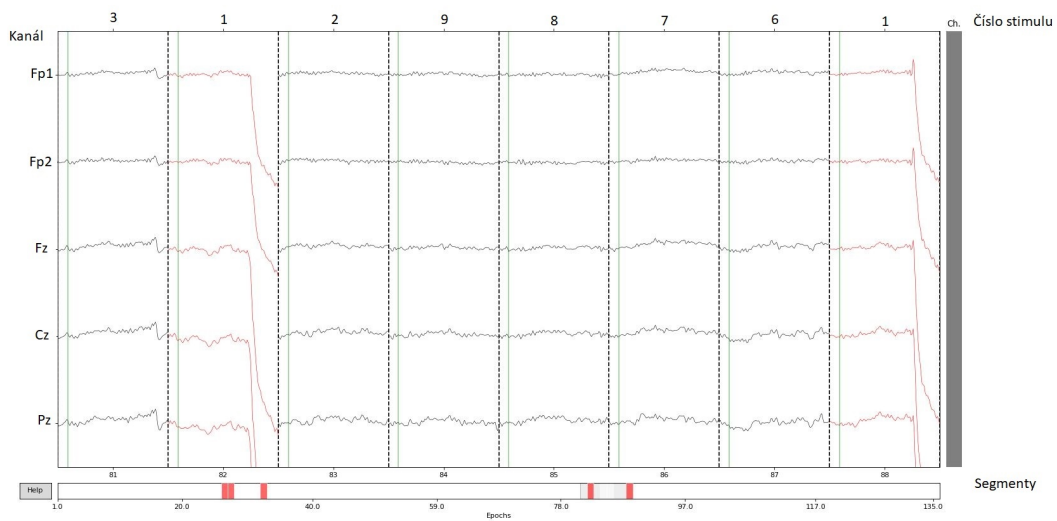
3.4.2 Segmentování do epoch

Segmentování do epoch je způsob úpravy signálu, při kterém se vyselektuje pouze určitý úsek v okolí stimulační značky, která se zaznamenává do měřených dat při spuštění každého stimulu. Vhodný rozsah se pro každé měření liší. Pozorovala jsem dobu latence u několika signálů, které byly měřeny a na základě tohoto pozorování zvolila rozsah 100 ms před stimulací a 1000 ms po začátku stimulace. Vysegmentované epochy jsou uloženy v poli, kde se uchovávají společně se seznamem stimulů. Na obrázku (Obr. 3.6) je přehledně zobrazena část pole s epochami, kde jsou v horní části vypisovány stimulační značky, v levé kanály, na kterých byl signál měřen, a ve spodní časová osa.

Následující dva grafy dokazují, že je důležité vhodně nastavit rozsah segmentace. Na obrázku (Obr. 3.6) je rozsah zvolen od 200 ms před vyvoláním stimulu po 800 ms od počátku stimulace. Z grafického vyobrazení je zřejmé, že takový rozsah není vhodný, protože vrchol amplitudy související s mrkáním začíná až těsně u konce segmentu a je špatně rozpoznatelný. Druhý graf (Obr. 3.7) vyobrazuje rozsah segmentu, který jsem zvolila pro tuto práci. V tomto segmentu je amplituda dostatečně vyselektována.



Obrázek 3.6: Rozsah segmentace nastavený od 200 ms před stimulem po 800 ms po počátku stimulace.




Obrázek 3.7: Rozsah segmentace nastavený od 100 ms před stimulem po 1000 ms po počátku stimulace.

3.4.3 Extrakce příznaků

Extrakce příznaků je metoda, při které se transformují předzpracované signály na hodnoty odpovídající základnímu neurologickému mechanismu. Metoda, kterou jsem zvolila je průměrování jednotlivých úseků epoch a z následných průměrů vytvoření jednotlivých složek vektoru X , který slouží jako vstupní parametr klasifikátoru. Ve své práci jsem zvolila rozsah úseku 50 ms, jež se po experimentálním testování na trénovací sadě osvědčil jako adekvátní.

Na obrázku (Obr. 3.8) je vyznačena časová osa jedné epochy. Jednotlivé časové úseky z 5 EEG kanálů byly naskládány vedle sebe. Z každého kanálu bylo průměrováním po padesáti vzorcích od 0 ms do 1000 ms získáno 20 vzorků pro každý z pěti kanálů. Výsledný vektor příznaků je ve tvaru $X=[x_1, x_2, \dots, x_{100}]$.



Obrázek 3.8: Časová osa jedné epochy. Oranžová šipka znázorňuje úsek 50 ms, ze kterých je vytvořen jeden průměr.

3.5 Realizace algoritmů

3.5.1 LDA

Pro LDA klasifikaci jsem zvolila knihovnu ScikitLearn jazyka Python, která je vybavena metodami k nastavení klasifikátoru založeném na Bayesovském rozhodovacím pravidle. Na základě experimentálního testování výstupů klasifikátoru byly nastaveny nejvhodnější parametry následovně:

- *solver='svd'* - tento algoritmus je doporučen pro data s velkým počtem příznaků, protože nepočítá kovariační matici, čímž je výpočet urychlen.
- *store_covariance=False* - výpočet kovariační matice.
- *tol=0.0001* - práh používaný k odhadu pozice v svd algoritmu.

3.5.2 Neuronové sítě

K implementaci neuronové sítě jsem zvolila knihovnu Keras jazyka Python, které je vybavena metodami pro nastavení klasifikátoru.

Návrh sítě

Pro klasifikaci pomocí neuronové sítě jsem zvolila vícevrstvou architekturu se třemi vrstvami (Obr. 3.10). Hustota vstupní vrstvy je 64 neuronů, skrytá vrstva je tvořena 32 neurony a výstupní vrstvu tvoří pouze jeden neuron. U každé vrstvy je použito nastavení plného propojení neuronů. To znamená, že neuron z vyšší vrstvy je propojen se všemi neurony ve spodní vrstvě. Síť jsem navrhovala na základě experimentálních testů s trénovací sadou dat. Parametry byly nastaveny následovně:

Vstupní vrstva:

```
model.add(Dense(64, input_dim=input_dim, activation='relu'))
```

- *Dense* - hustota vstupní vrstvy.
- *64* - počet neuronů.
- *activation='relu'* - aktivační funkce vstupní vrstvy (Obr. 3.9).
- *input_dim=* - dimenze vstupní vrstvy.
- *Dropout(0.2)* - zabraňuje přeučení sítě.

Skrytá vrstva:


- *Dense* - hustota vstupní vrstvy.
- *32* - počet neuronů.
- *activation='relu'* - aktivační funkce skryté vrstvy (Obr. 3.9).
- *Dropout(0.2)* - zabraňuje přeučení sítě.

Výstupní vrstva:

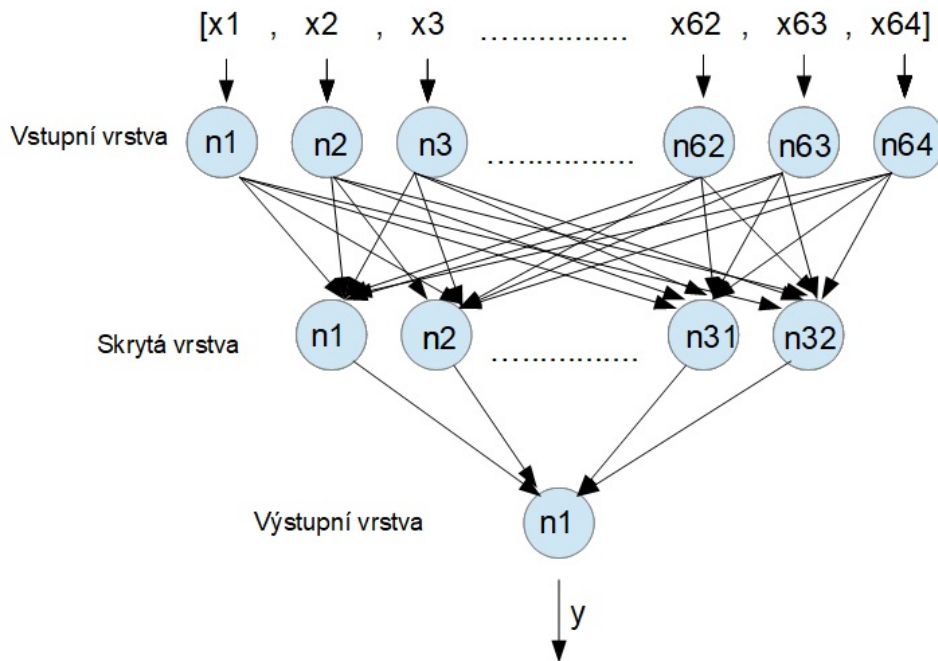
- *1* - počet neuronů.
- *activation='sigmoid'* - aktivační funkce výstupní vrstvy (Obr. 3.9).

Nastavení modelu:

- *optimizer='rmsprop'* - rmsprop využívá velikost nedávných přechodů pro normalizaci přechodů.
- *loss='binary_crossentropy'* - chybová funkce.
- *metrics=['accuracy']* - seznam metrik, které má model vyhodnotit.



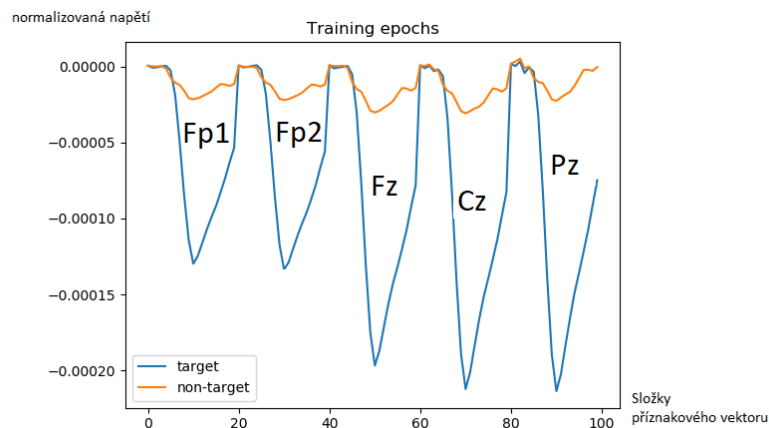
Obrázek 3.9: Grafy aktivačních funkcí relu a sigmoid.
(Zdroj: <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>)



Obrázek 3.10: Navržené schéma implementované neuronové sítě.

Vytvoření modelu a trénování

Vytvoření modelu probíhá na základě navržené topologie, podle které nastavím v programu jednotlivé vrstvy sítě. Data, která byla přidělena pro natrénování modelu jsou předzpracována stejným způsobem, jako ta, která se budou klasifikovat, ale nesou s sebou navíc informaci označující targetové a netargetové epochy. Pro správnou klasifikaci je vhodné modelu předat obě skupiny dat ve vyváženém množství (Obr. 3.11). Vytvořenému modelu sítě jsou data předána jako pole příznakových vektorů $X = [x_1, x_2, \dots, x_n]$, a vektor $Y = [y_1, y_2, \dots, y_n]$, kde pro každé $x_k \exists y_k$.



Obrázek 3.11: Zprůměrovaná množina trénovacích dat předaných modelu. Modře jsou vyznačeny příznaky, které budou při učení klasifikátoru targetové, na oranžově vyznačených příznacích se bude klasifikátor učit rozpoznat netargetové příznaky. Z obrázku je patrné, že nejsilnější signál byl na elektrodách Cz a Pz.

3.6 Využití technologie

3.6.1 Jazyk a nástroje

Program byl vytvářen na platformě Windows 10 Home edition a napsán v programovacím jazyce Python 3.6 ve vývojovém prostředí Eclipse Oxygen.2 Release (4.7.2). K načítání a předzpracování dat jsem využila knihovnu MNE

0.15.2. [13]. K implementaci klasifikačních algoritmů jsem použila knihovnu Scikit-Learn 0.19.1 [19], která je navržena pro LDA klasifikaci, knihovnu Keras 2.1.5 [8] a TensorFlow [2], vlastními prostředky k implementaci neuro-nových sítí.

3.6.2 Přehled funkcí v programu

Název	Popis	Package
def load_training_data_names():	Metoda načte ze souboru subject_target_train názvy souborů s daty určenými pro trénování klasifikátoru.	i_o
def load_predicting_data_names():	Metoda načte ze souboru subject_target_test názvy souborů s daty určenými ke klasifikaci.	i_o
def filter_epochs_target (epochs, target, instruction):	Metoda vrátí pole vyselektovaných epoch, které obsahují pouze targetové (nontargetové) segmenty, podle parametru <i>target</i> na vstupu.	logic
def feature_vector(epochs):	Metoda z epoch na vstupu vytvoří příznakové vektory a vrátí pole vytvořených vektorů.	logic
def mix_data(x, y):	Metoda promíchá příznakové vektory a jejich targetové značky. Vše probíhá synchronně, aby se neztratilo spojení jednotlivých vektorů a jejich značek.	logic

Tabulka 3.1: Přehled funkcí programu 1.

Název	Popis	Package
def solve_lda (x_train, y_train, x_test):	Metoda pro LDA klasifikaci příznakových vektorů. Vrací pole, ve kterém jsou uložena ohodnocení jednotlivých příznaků ve tvaru 1/0.	predict
def train_nn (x,y):	Na základě trénovací sady x a jejího ohodnocení y , vytvoří a natrénuje model, který využije neuronové sítě při klasifikaci.	predict
def solve_nn (x_predict):	Metoda pro klasifikaci příznakových vektorů neuronovými sítěmi. Vrací pole ohodnocení jednotlivých příznaků.	predict
def display_history (hist):	V této metodě jsou vytvořeny a zobrazeny grafy historie trénovací a validační sady.	display
def print_guess (guess_results, epochs_to_predict, true_label_first, true_label_second, instruction):	Vytiskne na konzoli výsledky klasifikace.	display
def accuracy (mapResults, true_label_first, true_label_second, number_of_all, instruction):	Spočítá procentuální spolehlivost výsledné klasifikace.	results_print
def precision (mapResults, true_label_first, true_label_second, instruction):	Spočítá procentuální přesnost výsledné klasifikace.	results_print

Tabulka 3.2: Přehled funkcí programu 2.

Název	Popis	Package
def recall (mapResults, true_label_first, true_label_second, instruction):	Spočítá procentuální výtěžnost výsledné klasifikace.	results_print
def count_results_matrix (mapResults):	Spočítá epochy označené klasifikátorem jako targetové pro stimulaci maticí.	results_print
def count_results_instruction (mapResults):	Spočítá epochy označené klasifikátorem jako targetové pro stimulaci obrázkem.	results_print

Tabulka 3.3: Přehled funkcí programu 3.

4 Dosažené výsledky testování

4.1 Výsledky klasifikací

Výsledek klasifikace za pomoci neuronových sítí je závislý na natrénovaném modelu, jež je pokaždé natrénován odlišně z důvodu náhodného nastavení parametrů. Z tohoto důvodu jsou data vypsaná v následujících tabulkách získána klasifikací s použitím modelu "../save_models/mymodel_1.h5", který jsem po natrénování uložila.

tp - správné pozitivní detekce

tn - správné negativní detekce

fp - falešné pozitivní detekce

fn - falešné negativní detekce

Accuracy (spolehlivost) je procentuální vyjádření spolehlivosti klasifikace, jako podíl součtu správně vyhodnocených se součtem všech.

$$A = \frac{tp+tn}{tp+tn+fp+fn}$$

Precision (přesnost) je procentuální vyjádření přesnosti klasifikace, jako podíl správné detekce targetů se součtem správně a falešně vyhodnocených targetů.

$$P = \frac{tp}{tp+fp}$$

Recall (výtěžnost) procentuálně vyjadřuje podíl správné detekce targetů se součtem správné detekce targetů a falešné detekce netargetů.

$$R = \frac{tp}{tp+fn}$$

Sloupce v tabulce naměřených hodnot:

- Subjekt - číslo experimentu.
- Zvolený obrázek - obrázek zvolený subjektem.

- Klasifikace LDA - obrázek vyhodnocený klasifikátorem LDA.
- Klasifikace NN - obrázek vyhodnocený neuronovými sítěmi.
- A_L - accuracy LDA
- A_N - accuracy NN
- P_L - precision LDA
- P_N - precision NN
- R_L - recall LDA
- R_N - recall NN

Výsledky stimulace obrázkem

Subjekt	Zvolený obrázek	Klasifikace		Výsledky klasifikace jednotlivých epoch					
		LDA	NN	$A_L\%$	$A_N\%$	$P_L\%$	$P_N\%$	$R_L\%$	$R_N\%$
1	jídlo	okno	jídlo	63.7	100	3.92	100	13.33	100
2	dveře	dveře	dveře	99.26	100	90.91	100	66.67	100
4	toaleta	toaleta	toaleta	93.33	99.26	60.87	93.75	93.33	100
5	dveře	dveře	dveře	98.52	97.78	86.67	83.33	86.67	100
7	televize	televize	televize	84.62	94.87	33.33	68.42	60.0	86.67
9	dveře	dveře	dveře	81.97	79.51	26.67	37.5	53.33	100

Tabulka 4.1: Výsledky klasifikace - stimulace obrázkem.

Výsledky stimulace maticí

Subjekt	Zvolený obrázek	Klasifikace		Výsledky klasifikace jednotlivých epoch					
		LDA	NN	$A_L\%$	$A_N\%$	$P_L\%$	$P_N\%$	$R_L\%$	$R_N\%$
2	R1 C1	R1 C1	R1 C1	98.33	100	93.1	100	67.5	100
4	R3 C1	R3 C1	R3 C1	94.17	100	84.44	100	95.0	100
5	R1 C1	R1 C1	R1 C1	100	100	100	100	97.5	100
7	R3 C2	R3 C2	R3 C2	84.17	92.5	64.15	80.85	85.0	95.0
9	R1 C1	R1 C1	R1 C2	90.83	72.5	75.56	44.07	85.0	65.0

Tabulka 4.2: Výsledky klasifikace - stimulace maticí.

4.1.1 Zhodnocení výsledků jednotlivých subjektů

Měření jsem prováděla celkem na dvanácti subjektech, které byly náhodně rozděleny na trénovací a testovací sadu. Výsledky měření jsou očíslovány podle skutečného pořadí měřených osob. Zbylá data, která se zde nenachází, byla použita na trénování klasifikátorů.

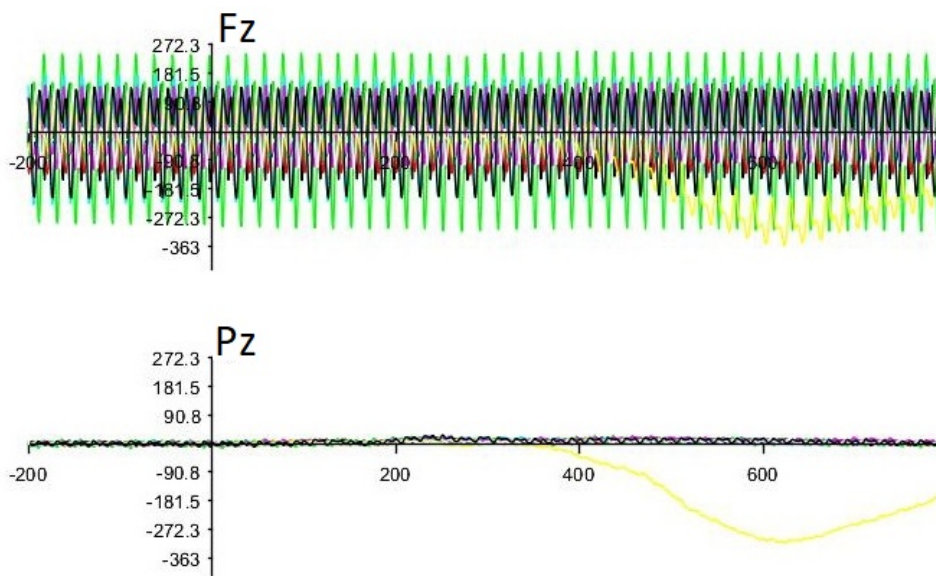
Měření č.1

Při tomto experimentu jsem měla problém s elektrodou Fz, přes vškerou snahu se mi nepodařilo snížit odpor na méně než $59k\Omega$. V průběhu experimentu bylo na první pohled vidět, že signál na této elektrodě je oproti ostatním mnohem více zašuměn (Obr. 4.1). Zvoleným obrázkem bylo *jídlo*, které LDA klasifikátor mylně vyhodnotil jako *okno*, neuronové sítě nad očekávání rozpoznaly cíl uživatele na 100%.

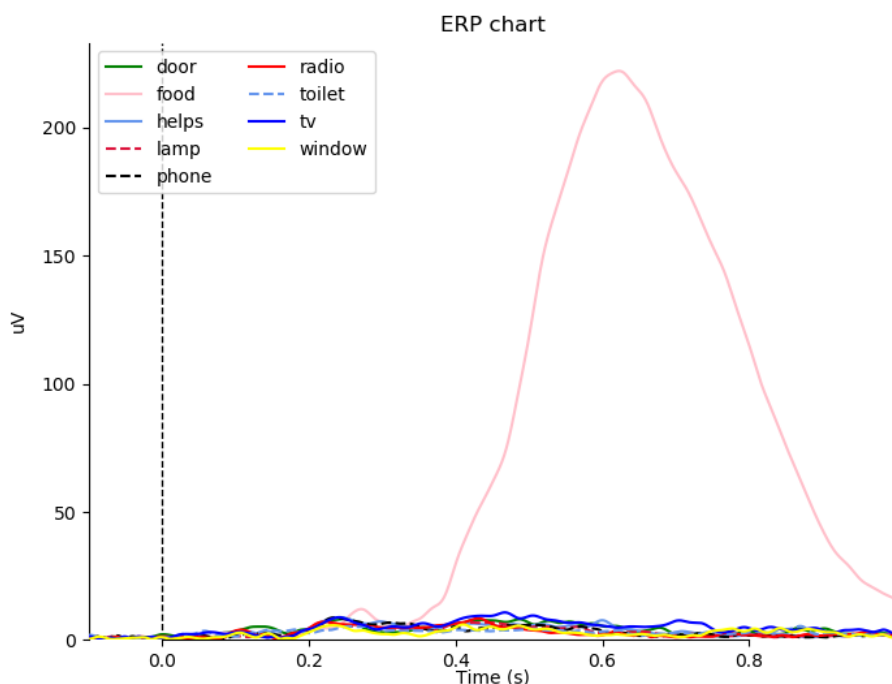
Měřeným subjektem byl muž ve věku 40let, silný kuřák, zdravý.

Grafy signálů elektrod Fz a Pz. (Obr. 4.1).

Graf segmentů jednotlivých stimulů při stimulaci maticí (Obr. 4.2).



Obrázek 4.1: Grafy signálů elektrod Fz a Pz z měření č1. Na Fz elektrodě je znatelné zašumění signálu v důsledku velkého odporu na vstupu signálu.



Obrázek 4.2: Graf vytvořených epoch z měření č.1. - stimulace obrázkem.

Měření č.2

Ve druhém měření jsem měla stejný problém s elektrodou Fz, následně se ukázalo, že problém není v subjektech, ale v zesilovači. Po přepojení elektrody Fz na jiný kanál nedělalo snížení odporu problém.

Měření probíhalo bez komplikací, ale při druhé stimulaci začalo subjekt pálet v očích. Tato komplikace se nijak neprojevila na kvalitě signálu. Zvoleným obrázkem byly *dveře*, které LDA klasifikátor i neuronové sítě vyhodnotily správně. Klasifikace neuronovými sítěmi dopadla ve všech bodech na 100%. LDA klasifikace byla horší. Měřeným subjektem byl muž ve věku 55let, kuřák, zdravý, nosí brýle na čtení.

Měření č.4

Měření probíhalo bez komplikací. Zvoleným obrázkem byla *toaleta*, kterou LDA klasifikátor i neuronové sítě vyhodnotily správně. Klasifikace neuronovými sítěmi dopadla ve všech bodech stimulace maticí na 100%, při stimulaci obrázkem byla spolehlivost a přesnost trochu nižší. LDA klasifikace byla opět

horší ve všech bodech.

Měřeným subjektem byl muž ve věku 28let, kuřák, zdravý, sportuje.

Měření č.5

Měření probíhalo bez komplikací. Zvoleným obrázkem byly *dveře*, které LDA klasifikátor i neuronové sítě vyhodnotily správně. Klasifikace neuronovými sítěmi u tohoto subjektu dopadla pro stimulaci obrázkem o něco hůře než LDA, pouze její výtěžnost byla 100%. U stimulace maticí byla výtěžnost LDA trochu nižší. Pro tento subjekt oba algoritmy klasifikovaly s velice dobrým výsledkem.

Měřeným subjektem byl muž ve věku 26let, nekuřák.

Měření č.7

U tohoto subjektu jsem měla problém se snížením odporu na referenční elektrodě a čelních elektrodách Fp1,Fp2. Měřený měl poměrně velkou lebku na níž se obtížně nasazovala zvolená největší EEG čepice. Zřejmě z důvodu silné pokožky na čele se mi přes veškeré úsilí nepodařilo odpor snížit. Výsledné odpory zmíněných elektrod byly následující: Fp1 = 21 k Ω Fp2 = 22 k Ω referenční elektroda = 2 k Ω .

Měření probíhalo bez komplikací. Zvoleným obrázkem byla *televize*, kterou LDA klasifikátor i neuronové sítě vyhodnotily správně. Z výsledků je patrné, že zřejmě v důsledku hůře naměřených vstupních dat LDA klasifikátor rozpoznal zvolený stimul s výrazně horší přesností než neuronové sítě. Měřeným subjektem byl muž ve věku 28let, nekuřák.

Měření č.9

Při aplikaci EEG čepice tomuto subjektu jsem neměla žádné potíže. Ve srovnání s jinými byla jeho příprava na měření nejsnažší. Odpory na elektrodách byly sníženy při první aplikaci gelu, bez nutnosti úprav. Zvoleným obrázkem byly *dveře*, které LDA klasifikátor i neuronové sítě vyhodnotily správně v

případě stimulace obrázkem. U stimulace maticí neuronové sítě klasifikovaly chybný výsledek.

Měřeným subjektem byl muž ve věku 35let, silný kuřák. Muž trpí častými výpadky krátkodobé paměti způsobenými těžkou autonehodou a poraněním hlavy. Poměrně často konzumuje tvrdý alkohol - několikrát do týdne. Z výsledků obou klasifikací je patrné, že v tomto případě ani jeden z klasifikátorů nebyl procentuálně příliš úspěšný. Vzhledem k dobré kvalitě umístění aplikovaných elektrod nedokáží přesně určit příčinu nekvalitních klasifikací. V tomto případě je možné uvažovat, že může být chyba na straně subjektu.

4.1.2 Celkové zhodnocení

Spočítala jsem průměry výsledků klasifikací jednotlivých epoch ze všech měření (Tab. 4.3) a na základě tohoto porovnání došla k závěru, že klasifikace pomocí neuronových sítí je v celkovém zhodnocení jednoznačně přesnější metoda.

Z velkého množství experimentů, které jsem prováděla na testovací sadě a z výsledků různých klasifikací jsem zjistila, že nejlepší metodou pro předpokládaný úspěch je natrénování několika modelů a při klasifikaci používání natrénovaného vyzkoušeného modelu. Vzhledem k již zmíněnému náhodnému nastavování parametrů neuronové sítě při trénování modelu se někdy stane, že model není natrénován dobře a neuronové sítě mají chybné výsledky klasifikací.

Celkové průměry výsledků klasifikací

	$A_L\%$	$A_N\%$	$P_L\%$	$P_N\%$	$R_L\%$	$R_N\%$
Obrázek	86,9	95,24	50,4	80,5	62,22	97,78
Matice	93,5	93	83,45	84,98	86	92
Celkový průměr	90,2	94,12	66,93	82,74	74,11	94,89

Tabulka 4.3: Porovnání celkových průměrů výsledků klasifikací.

5 Závěr

Tato práce byla zaměřena na seznámení se s problematikou elektroencefalografie, asistenčních systémů založených na detekci artefaktů, a neuronových sítí z kategorie hlubokého učení.

Prostudovala jsem literaturu týkající se dané problematiky a vypracovala teoretickou část, kde jsou vysvětleny principy získávání EEG dat a jejich následovné předzpracování. V další kapitole popisuji BCI systémy, které jsou založené na mozkové aktivitě a asistenční systémy založené na svalových artefaktech, jejichž klasifikace je, narozdíl od BCI, snažší. V poslední části teorie uvádím informace o LDA klasifikátoru a neuronových sítích (NN).

Hlavním cílem byl návrh a implementace části asistenčního systému. Navrhla a implementovala jsem LDA klasifikátor, a po otestování došla k závěru, že výstup klasifikace byl většinou správný, ale procentuální výsledky přesností nebyly příliš uspokojivé. Následně jsem navrhla a implementovala NN s použitím knihovny keras pro hluboké učení, které byly v celkovém srovnání procentuálně přesnější. Experimentálně jsem zjistila, že dopředná síť s jednou skrytou vrstvou dosahuje stejných výsledků jako složitější hluboké síť. Pravděpodobnou příčinou je relativní jednoduchost vstupních dat.

Výsledky klasifikace LDA úplně nesplnily má očekávání. Vzhledem k rozpoznávání poměrně velké amplitudy jsem očekávala procentuálně vyšší spolehlivost. Proto považuji klasifikaci pomocí NN v dané problematice za jednoznačně lépe zvolenou metodu.

Mnou navržená část asistenčního systému probíhá offline, to znamená, že data nejprve naměřím a až poté předám programu ke klasifikaci. Takový systém zatím nelze využívat jako reálný asistenční systém, ale část systému, kterou jsem implementovala je vhodně připravena pro možné budoucí využití v online systému, který by mohl být reálně využíván.

Při získávání dat nedocházelo ke komplikacím, ale dva subjekty nereagovaly na nasazení EEG čepice příliš dobře. Z tohoto důvodu nebylo možné jedno měření zrealizovat vůbec, druhé po otevření okna a poskytnutí dostatečného množství vody proběhlo. Na základě toho jsem došla k závěru, že získávání dat s EEG čepicí není vhodné pro každého.

Seznam použitých zkratek

BCI	Brain-Computer Interfaces (Rozhraní mozek - počítač)
EEG	Electroencephalography (Elektroencefalografie)
EP	Evoked Potentials (Evokovaný potenciál)
VEP	Visual Evoked Potentials (Zrakově evokované potenciály)
SSVEP	Steady State Visually Evoked Potential (Ustálené zrakově evokované potenciály)
LDA	Linear Discriminant Analysis (Lineární diskriminační analýza)
NN	Neural Network (Neuronové sítě)
MNE	MEG + EEG Analysis Visualization
svd	Singular value decomposition (Rozklad na jednotlivá čísla)

Seznam obrázků

2.1	Hodnoty vybraných elektrických biosignálů	2
2.2	Rozmístění elektrod systémem 10-20.	4
2.3	Označení elektrod.	5
2.4	Rozdělení mozkových oblastí.	5
2.5	Mozkové vlny	7
2.6	Meření sluchového EP.	8
2.7	SSVEP amplituda.	9
2.8	Ukázka několika technických artefaktů v signálu.	10
2.9	Ukázka několika biologických artefaktů v signálu.	10
2.10	Svaly oka.	11
2.11	Ukázka mrknutí v signálu	11
2.12	Architektura BCI systému.	12
2.13	Segmentace na jednotlivé epochy	16
2.14	Průměrování jednotlivých epoch	16
2.15	Struktura biologického neuronu	19
2.16	Umělý neuron	20
2.17	Vícevrstvá neuronová síť.	21
3.1	Implementované elektrody.	24
3.2	Printscreen stimulace 2. měření.	25
3.3	Ukázka časového grafu zobrazení stimulu.	26
3.4	Signál před aplikací filtru.	28
3.5	Signál po aplikaci filtru.	28
3.6	Rozsah segmentace nastavený -200 ms - 800 ms.	30
3.7	Rozsah segmentace nastavený -100 ms - 1000 ms.	30
3.8	Časová osa jedné epochy.	31
3.9	Grafy aktivačních funkcí relu a sigmoid.	33
3.10	Navržené schéma implementované neuronové sítě.	33
3.11	Zprůměrovaná množina trénovacích dat.	34
4.1	Grafy signálů elektrod Fz a Pz z měření č1.	40
4.2	Stimulace obrázkem - měření č.1.	41
A.1	První dialog po spuštění programu.	52
A.2	Graf vytvořených epoch z měření.	53
A.3	Dotaz na volbu modelu.	54
A.4	Dotaz na zobrazení obrázku.	54

A.5 Graf trénvacích příznaků.	54
A.6 Ukázka průběhu trénování nového modelu.	55
A.7 Výsledné klasifikace.	55

Seznam tabulek

3.1	Přehled funkcí pogramu 1.	35
3.2	Přehled funkcí pogramu 2.	36
3.3	Přehled funkcí pogramu 3.	37
4.1	Výsledky klasifikace - stimulace obrázkem.	39
4.2	Výsledky klasifikace - stimulace maticí.	39
4.3	Porovnání celkových průměrů výsledků klasifikací.	43

Literatura

- [1] Artifact in Electroencephalography. *Annals of Clinical Neurophysiology*. 2003, 5, 1, s. 157–169. Dostupné z: <http://www.e-acn.org/journal/view.php?myear=2003&vol=5&no=1&spage=157>.
- [2] ABADI, M. et al. TensorFlow: A System for Large-Scale Machine Learning. In *OSDI*, 16, s. 265–283, 2016.
- [3] BALEK, B. Elektrické biosignály lidského těla měřené ISESem. *Souhrnný sborník Veletrhu nápadů učitelů fyziky [online]*. 2011.
- [4] BUDÍKOVÁ, M. *Přednáška Lineární diskriminační analýzy [online]*. 2018. Dostupné z: <https://is.muni.cz/el/1431/jaro2015/MAS02/um/54525918/prednaska6.pdf>.
- [5] BUDZYNSKI, T. H. et al. *Introduction to quantitative EEG and neurofeedback: Advanced theory and applications*. Academic Press, 2009.
- [6] CATON, R. Electrical Currents of the Brain. *The Journal of Nervous and Mental Disease*. 1875, 2, 4, s. 610.
- [7] CHIAPPA, K. H. *Evoked potentials in clinical medicine*. Lippincott Williams & Wilkins, 1997. ISBN 0-397-51659-2.
- [8] CHOLLET, F. – OTHERS. Keras. <https://keras.io>, 2015.
- [9] SILVA, I. N. et al. Artificial Neural Network Architectures and Training Processes. In *Artificial Neural Networks*. : Springer, 2017. s. 21–28.
- [10] DU BOIS-REYMOND, E. H. – MÜLLER, J. H. J. *On Animal Electricity: Being an Abstract of the Discoveries of Emil Du Bois-Reymond...* John Churchill, Princes Street, Soho., 1852.
- [11] FETZ, E. E. Operant conditioning of cortical unit activity. *Science*. 1969, 163, 3870, s. 955–958.
- [12] GOODFELLOW, I. et al. *Deep learning*. 1. MIT press Cambridge, 2016. ISBN 978-0262035613.
- [13] GRAMFORT, A. et al. MEG and EEG data analysis with MNE-Python. *Frontiers in neuroscience*. 2013, 7, s. 267.
- [14] HOLČÍK JIŘÍ, K. M. e. a. k. *Matematická biologie: e-learningová učebnice*. 1. vydání. Brno: Masarykova univerzita, 2015. ISBN 978-80-210-8095-9.

- [15] JAROMÍR ŠVEJDA, R. J. R. K. Zpracování Mozkové Aktivity V Bci Systémech. *Odborný vědecký časopis Trilobit / © 2009 - 2018 Fakulta aplikované informatiky UTB ve Zlíně [online] / ISSN 1804-1795*. 2012.
- [16] LUCK, S. J. *An Introduction to the Event-Related Potential Technique (Cognitive Neuroscience)*. A Bradford Book, 1 edition, August 2005. Dostupné z: <http://www.amazon.com/exec/obidos/redirect?tag=citeulike07-20&path=ASIN/0262621967>. ISBN 0262621967.
- [17] LUSTIG, F. Školní laboratoře badatelského typu–integrace tradičních, vzdálených a virtuálních fyzikálních experimentů. In *Sborník konference Veletrh nápadů učitelů fyziky 16. 2.-4., 9*, s. 165–172. Citeseer, 2011.
- [18] MÜLLER-PUTZ, G. R. et al. Steady-state visual evoked potential (SSVEP)-based communication: impact of harmonic frequency components. *Journal of neural engineering*. 2005, 2, 4, s. 123.
- [19] PEDREGOSA, F. et al. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*. 2011, 12, s. 2825–2830.
- [20] SANEI, S. – CHAMBERS, J. A. *EEG Signal Processing*. Wiley-Interscience, Sep 2007. Dostupné z: <http://www.amazon.ca/exec/obidos/redirect?tag=citeulike09-20%5C&path=ASIN/0470025816>. ISBN 0470025816.
- [21] SELVAM, V. S. – SHENBAGADEVI, S. Brain tumor detection using scalp EEG with modified wavelet-ICA and multi layer feed forward neural network. In *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*, s. 6104–6109. IEEE, 2011.
- [22] SORUDEYKIN, K. A. An educative brain-computer interface. *arXiv preprint arXiv:1003.2660*. 2010.
- [23] UDAYASHANKAR, A. et al. Assistance for the Paralyzed Using Eye Blink Detection. In *2012 Fourth International Conference on Digital Home*, s. 104–108, Nov 2012. doi: 10.1109/ICDH.2012.9.
- [24] VOLNÁ, E. Neuronové sítě 1. *Ostrava: Ostravská univerzita v Ostravě. Vydání: druhé*. 2008.

A Přílohy

A.1 Obsah CD

Přiložené CD obsahuje následující soubory a adresáře:

- **Souhlas s měřením.pdf** - obsahuje šablonu souhlasu s naměřením dat a krátký dotazník. Stejné souhlasy před měřením vyplňovaly všechny subjekty a jsou uloženy v na KIV v kanceláři UN 324.
- **Program**
 - **configuration** - tento modul obsahuje třídu *config*, která obsahuje všechny důležité konfigurace programu.
 - **display** -
 - **io** - zde jsou třídy pro tisk výsledků klasifikace a zobrazení historie trénování.
 - **logic** - načítání názvů vstupních souborů.
 - **predict** - klasifikátory.
 - **raw_data** - soubory a naměřenými daty.
 - **results_print** - počítá a tiskne procentuální výsledky klasifikací.
 - **save_models** - uložené modely a k nim příslušné grafy z trénování. V konfiguraci je nastavený model:
saved_model_path='./save_models/mymodel_1.h5'.
V *configuration.config* lze přepínat načítání modelů na jiné z tohoto souboru.
 - **main.py**
 - **run.cmd** - spouštěcí skript.
 - **subject_target_train**
 - **subject_target_test**
- **Bakalářská práce.pdf**
- **thesis** - kód práce v LaTeXu.
- **graphs**
- **readme.txt**

A.2 Uživatelská dokumentace

Program je možné nalézt na příložením CD
nebo na adrese: <https://github.com/medunova/Assistance-system>.

Před spuštěním programu je nezbytné nainstalovat následující knihovny:

Python 3.6 -> <https://anaconda.org/anaconda/python>

MNE-Python

-> https://www.martinos.org/mne/stable/install_mne_python.html

Scikit-learn -> <http://scikit-learn.org/stable/install.html>

Keras -> <https://keras.io/#installation>

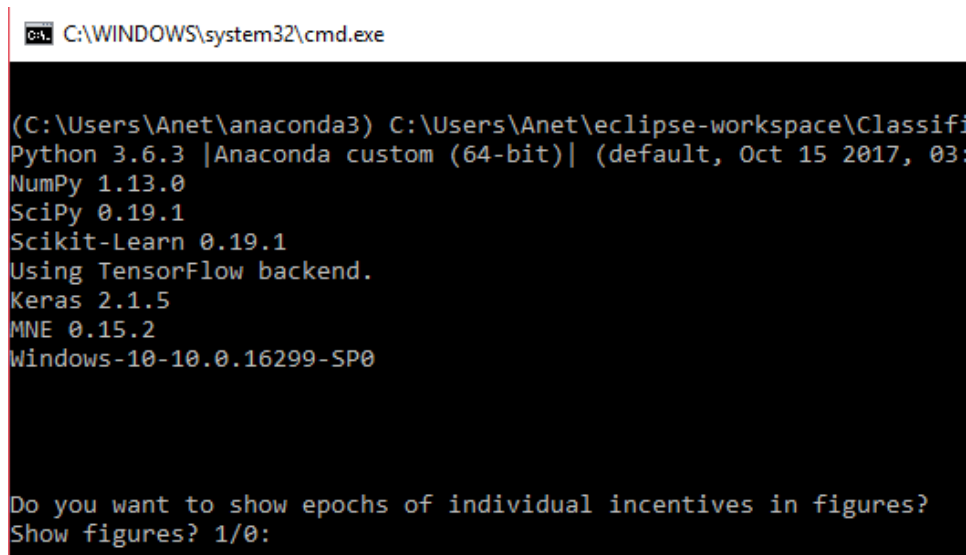
Tensorflow -> https://www.tensorflow.org/install/install_windows

Po úspěšné instalaci všech součástí je posledním krokem nastavení správné cesty k adresáři *anaconda3*. Toto nastavení je nutné udělat v souboru *run.cmd* (poklik pravou myší - > upravit), kde se nastaví:

```
set root=C:/VaseCesta/anaconda3.
```

- **Spuštění programu**

Program se spouští skriptem *run.cmd*, ve kterém bylo nutné nastavit cestu k adresáři *anaconda3*. Po spuštění programu se otevře příkazová řádka (Obr. A.1).



```
C:\WINDOWS\system32\cmd.exe

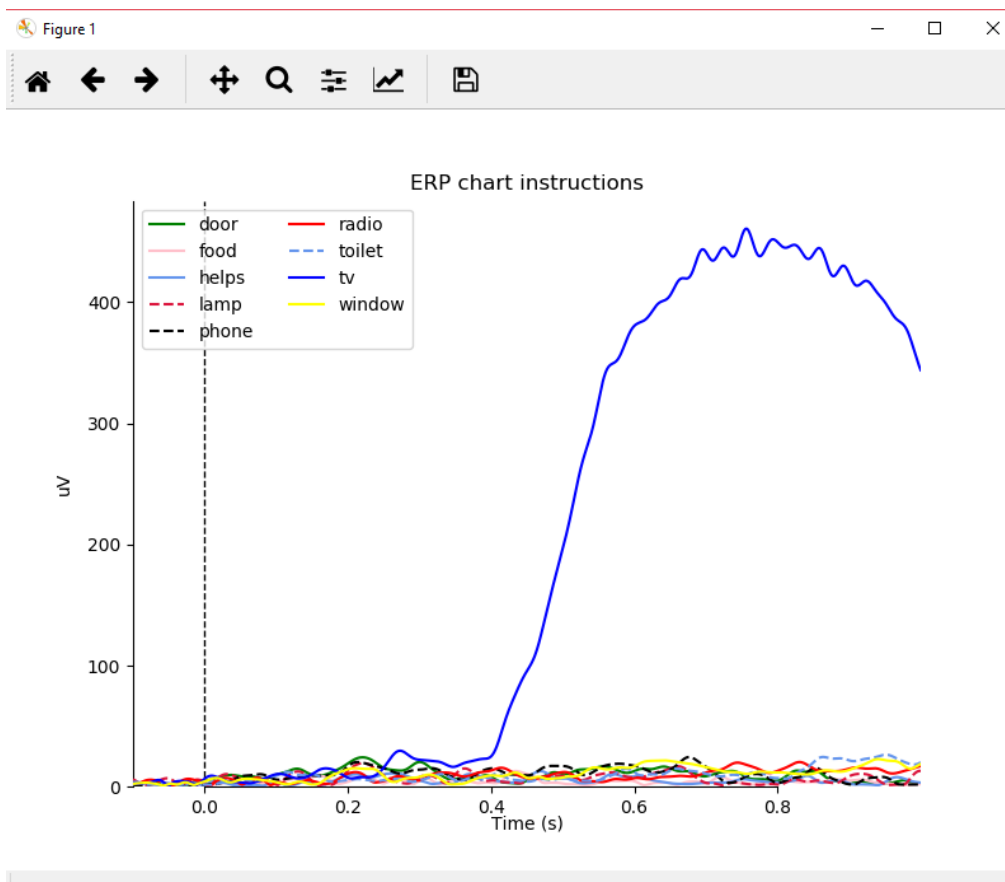
(C:\Users\Anet\anaconda3) C:\Users\Anet\eclipse-workspace\Classifi
Python 3.6.3 |Anaconda custom (64-bit)| (default, Oct 15 2017, 03:
NumPy 1.13.0
SciPy 0.19.1
Scikit-Learn 0.19.1
Using TensorFlow backend.
Keras 2.1.5
MNE 0.15.2
Windows-10-10.0.16299-SP0

Do you want to show epochs of individual incentives in figures?
Show figures? 1/0:
```

Obrázek A.1: První dialog po spuštění programu.

- **Zobrazení obrázků**

Po spuštění se program ptá, chcete-li zobrazit obrázky (Obr. A.1).
Volba **1** - postupně se zobrazí grafy epoch jednotlivých stimulů (Obr. A.2), které patří testovaným subjektům.
Volba **0** - program tento krok vynechá a pokračuje.



Obrázek A.2: Graf vytvořených epoch z měření.

- **Načtení modelu**

Program se vás zeptá, přejete-li si načíst již natrénovaný model nebo zvolit nové trénování modelu (Obr. A.3).
Volba **1** - model je načten ze souboru.
Volba **0** - program natrénuje nový model (Obr. A.6).

```
C:\WINDOWS\system32\cmd.exe

You can choose between a new model training or choose already trained model.
When choosing new model training there is a risk
of bad trained model due random setting of parameters.
If you want to load model from file: 1
If you want to train_nn new model : 0

Load model? 1/0:
```

Obrázek A.3: Dotaz na volbu modelu.

- **Grafické zobrazení příznaků**

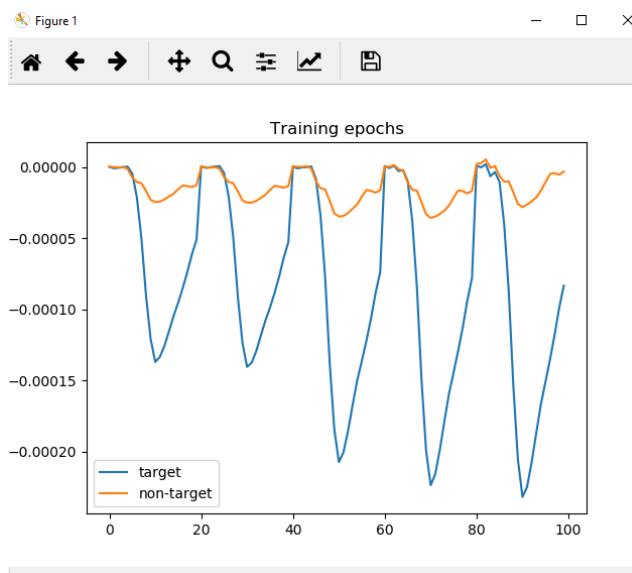
Pouze v případě volby trénování modelu. Program se vás zeptá, přejete-li si zobrazit graf příznaků testovací sady (Obr. A.4).

Volba **1** - zobrazí se graf (Obr. A.5) příznaků trénovací a validační sady.

Volba **0** - program tento krok vynechá a pokračuje.

```
Do you want to show figure od features vectors to train?
Show figures? 1/0:
```

Obrázek A.4: Dotaz na zobrazení obrázku.



Obrázek A.5: Graf trénovacích příznaků.

```
C:\WINDOWS\system32\cmd.exe
Epoch 15/300
436/436 [=====] - 1s 2ms/step - loss: 0.6843 - acc: 0.5917 - val_loss: 0.6825 - val_acc: 0.8636
Epoch 16/300
436/436 [=====] - 1s 2ms/step - loss: 0.6829 - acc: 0.6124 - val_loss: 0.6807 - val_acc: 0.5364
Epoch 17/300
436/436 [=====] - 1s 2ms/step - loss: 0.6795 - acc: 0.6445 - val_loss: 0.6774 - val_acc: 0.5818
Epoch 18/300
436/436 [=====] - 1s 1ms/step - loss: 0.6799 - acc: 0.6261 - val_loss: 0.6736 - val_acc: 0.7364
Epoch 19/300
436/436 [=====] - 1s 2ms/step - loss: 0.6734 - acc: 0.6514 - val_loss: 0.6696 - val_acc: 0.6818
Epoch 20/300
436/436 [=====] - 1s 2ms/step - loss: 0.6736 - acc: 0.6628 - val_loss: 0.6650 - val_acc: 0.7636
Epoch 21/300
436/436 [=====] - 1s 2ms/step - loss: 0.6628 - acc: 0.6720 - val_loss: 0.6605 - val_acc: 0.8455
Epoch 22/300
436/436 [=====] - 1s 2ms/step - loss: 0.6624 - acc: 0.6995 - val_loss: 0.6525 - val_acc: 0.7545
Epoch 23/300
436/436 [=====] - 1s 2ms/step - loss: 0.6532 - acc: 0.6812 - val_loss: 0.6456 - val_acc: 0.8273
Epoch 24/300
4/436 [.....] - ETA: 1s - loss: 0.6734 - acc: 0.5000
```

Obrázek A.6: Ukázka průběhu trénování nového modelu.

- **Zobrazení výsledků klasifikace**

V poslední fázi se na konzoli vytisknou výsledky klasifikace (Obr. A.7).

```
#####
15 .) Expected solve_lda: R1 C1
LDA:
R1 : 13
R2 : 0
R3 : 0
C1 : 14
C2 : 2
C3 : 0
Accuracy: 98.33 %
Precision is: 93.1 %
Recall is: 67.5 %
Neural network:
R1 : 19
R2 : 0
R3 : 0
C1 : 20
C2 : 0
C3 : 0
Accuracy: 100.0 %
Precision is: 100.0 %
Recall is: 97.5 %
```

Obrázek A.7: Výsledné klasifikace.