

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

Bakalářská práce

**Návrh jednoduchého
klasifikátoru pro detekci
změn spektrálních
vlastností EEG (tzv.
ERD/ERS) v souvislosti s
pohybem ruky**

Místo této strany bude
zadání práce.

Prohlášení

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

V Plzni dne 25. června 2019

Pavel Mochura

Abstract

Continual EEG activity in the measured subjects includes various types according to what the subject performed. ERD and ERS are examples of such types related to hand motion (finger or foot). This thesis deals with the detection of motion based on the ERD/ERS patterns. Through the connection of ERD/ERS, specific vectors which are classified by neural network are created. The resulting neural network consists of one input and one output layer and two hidden layers. The first hidden layer contains 3,000 neurons and the other one 1,500 neurons. A training set of specific vectors is used for the training of this neural network and the Backpropagation algorithm is used for the subsequent adjustment of weight. Within this setting and training, the neural network is able to classify motion in an EEG record with an average accuracy of 79.92%.

Abstrakt

Kontinuální EEG aktivita u měřených subjektů obsahuje různé vzory podle toho, co měřený subjekt vykonával. ERD a ERS jsou příklady takovýchto vzorů, které souvisejí s pohybem ruky (prstu, nohy). Tato práce se zabývá detekcí pohybu na základě ERD/ERS vzorů. Spojením ERD/ERS vznikají příznakové vektory, které jsou klasifikovány neuronovou sítí. Výsledná neuronová síť se skládá z jedné vstupní a výstupní vrstvy a ze dvou skrytých vrstev, kde první skrytá vrstva obsahuje 3 000 neuronů a druhá skrytá vrstva 1 500 neuronů. Pro trénování této neuronové sítě je použita trénovací množina příznakových vektorů a pro následné nastavování vah je použit algoritmus Backpropagation. S tímto nastavením a trénováním je neuronová síť schopna klasifikovat pohyb v EEG záznamu s průměrnou přesností 79,92%.

Poděkování

Na tomto místě bych chtěl poděkovat všem, kteří byli ochotni přijít na měření a poskytnout mi tímto cenná EEG data. Dále chci poděkovat Ing. Jiřímu Martínkovi za konzultaci ohledně konfigurace neuronové sítě. Především však chci poděkovat vedoucímu práce Ing. Pavlu Mautnerovi, Ph.D. za odborné vedení a pomoc jak při vlastním měření, tak i při následném zpracování dat.

Obsah

1	Úvod	8
2	Elektroencefalografie	9
2.1	Evokované potenciály	10
2.1.1	Zrakové evokované potenciály	10
2.1.2	Sluchové evokované potenciály	11
2.1.3	Somatosenzorické evokované potenciály	12
2.1.4	Motorické evokované potenciály	12
3	Pohyb v EEG	13
3.1	Kognitivní evokované potenciály	13
3.2	Přípravný motorický potenciál	13
3.3	Event-related synchronization a Event-related desynchroni- zation	15
3.3.1	Kvantifikace ERD/ERS v čase	16
3.3.2	Prostorové mapování ERD/ERS	17
4	Klasifikace pohybu v EEG	20
4.1	Umělé neuronové sítě	20
4.1.1	Typy umělých neuronových sítí	20
4.1.2	Strojové učení umělých neuronových sítí	21
5	Návrh postupu na detekci pohybu ruky v EEG záznamech	24
6	Návrh scénáře pro měření EEG	25
7	Měření EEG	26
7.1	Použitá technika pro měření	26
8	Příprava dat pro klasifikaci	30
8.1	výpočet ERD	30
8.2	výpočet ERS	34
8.3	Tvorba příznakových vektorů	34
9	Klasifikace	36
10	Testování	38

11 Závěr	40
Přehled Zkratk	41
Literatura	42
A Uživatelská příručka	46
A.1 Spuštění aplikací	46
A.2 Postup vykreslení grafů	46
B Obsah CD	48

1 Úvod

Už od dávných časů lidstvo sužuje velká spousta nemocí. Jednou z těchto nemocí je například mozková mrtvice, která může být způsobena například vysokým tlakem. Lidé, jež prodělali cévní mozkovou příhodu, mohou být trvale částečně ochrnutí a tím mít omezenou pohyblivost nějaké své končetiny. Pokud se mi úspěšně podaří navrhnout a implementovat dostatečně účinný klasifikátor, který bude v záznamech EEG detekovat pohyb, tak doufám, že právě těmto pacientům s omezenou hybností rukou bude při rehabilitacích velmi užitečný. Výše zmíněný klasifikátor bude možné použít například ve VR (virtuální realita). Postižený pacient si jen nasadí VR, kde bude nahraná libovolná kniha, ve které si bude moci pacient listovat podle své libosti pouze tím, že pomyslí na pohyb ruky.

První část této práce popisuje teoretické znalosti týkající se EEG signálu jako například různé druhy evokovaných potenciálů nebo jak je možné detekovat pohyb v EEG signálu za pomoci ERD/ERS (Event-related desynchronization/synchronization). Dále obsahuje stručný popis umělých neuronových sítí a několik učících metod.

Druhá část této práce podrobně líčí postup při měření subjektů pro způsob získání EEG dat nebo také způsob získání příznakových vektorů z EEG signálu použitím ERD/ERS. Poté také popisuje implementaci umělé neuronové sítě se dvěma skrytými vrstvami, následné testování a zhodnocení dosažených výsledků.

Pro zpracování dat je použit programovací jazyk Python, protože lze použít nástroj MNE, který je přímo určený pro zpracování, vizualizaci a analýzu lidských neurofyziologických dat. Pro implementaci klasifikátoru byl také použit programovací jazyk Python s využitím modulu Keras, který slouží pro rychlé a účinné modelování umělých neuronových sítí.

2 Elektroencefalografie

Elektroencefalografie (EEG) je metoda sloužící ke sledování mozkových funkcí. Provádí se pomocí přístroje zvaného elektroencefalograf, který se skládá ze snímacích elektrod umístěných ve speciální EEG čepici a zesilovače. Elektrody snímají elektrické potenciály, které vznikají synchronizovanou činností velkého počtu neuronů. Vzniklé EEG-křivky mají charakteristický vzhled. Jinou křivku zobrazí přístroj ve spánku, odlišnou při denní aktivitě. Aktivita mozku se liší frekvencí, podle které je rozdělena do různých pásem:

1. Alfa pásmo (8-13Hz) je aktivní při relaxaci nebo zavřených očích.
2. Beta pásmo (18-30Hz) je aktivní při koncentraci, logicko-analytickém myšlení či neklidu.
3. Gama pásmo (30Hz a více) se v souvislosti s EEG někdy ani neuvádí, ovšem je spojováno například s extrémní koncentrací.
4. Delta pásmo (3Hz a méně) je aktivní při hlubokém spánku či v patologické bdělosti.
5. Theta pásmo (3,5-7,5Hz) je aktivní při kreativním myšlení nebo usínání.

Dále se EEG signál skládá z několika komponent:

1. Aktivita pozadí (background activity) - Periodická aktivita, která charakterizuje stav mozku. Podle frekvence lze určit, zda měřený subjekt spí, relaxuje, koncentruje se nebo usíná.
2. Evokované potenciály - Krátkodobé změny EEG aktivity vzniklé v důsledku nějaké vnější stimulační aktivity.
3. Artefakty - Artefakty si lze představit jako druhy rušení a je možné je rozdělit do dvou základních skupin a to artefakty biologické a technické povahy. Artefakty technické povahy mohou být způsobeny například špatnou elektrodou. Biologické artefakty vytváří měřený subjekt například otevřením/zavřením očí nebo také pocením.

EEG vyšetření se provádí především u pacientů s poruchami vědomí (například při epilepsii), po operacích mozku, úrazech hlavy, chronických bolestech hlavy, degenerativních, zánětlivých nebo onkologických onemocněních apod.

2.1 Evokované potenciály

Evokované potenciály jsou změny v elektrické aktivitě mozku, ale i jiných částí nervové soustavy, ke kterým dochází vlivem vnějšího podnětu.

Evokované potenciály slouží k zhodnocení funkčního stavu příslušné nervové dráhy. Dále testují, jak moc dlouho mozků trvá přijmutí a interpretování daného podnětu (například zrakového). Při běžných podmínkách a za normálních okolností mozek reaguje téměř okamžitě. Pokud je nervový přenos nějak porušen, trvá reakce na podnět déle (například při roztroušené skleróze).

Velkou výhodou vyšetření pomocí evokovaných potenciálů je rychlost získání výsledků, protože již při samotném vyšetřování je výsledek vyšetření viditelný v průběhu na monitoru. Také je dobré poukázat na skutečnost, že se jedná o neinvazivní vyšetření, které pro pacienta nenesé v podstatě žádné riziko [1].

Podle typu podnětu, jakým jsou vyvolané evokované potenciály, rozlišujeme 4 typy EP:


1. VEP (zrakové EP = visual EP)
2. AEP (sluchové EP = acoustic EP)
3. SEP (somatosenzorické EP = somatosensory EP)
4. MEP (motorické EP = motoric EP)

Lze ovšem rozlišovat i jiné typy evokovaných potenciálů jako například:

1. SSEP (ustálené = steady state EP)
2. ERP (kognitivní EP = event related potentials)

2.1.1 Zrakové evokované potenciály

Evokované potenciály jsou všechny odpovědi nervového systému na dráždění receptoru, které se používají k vyhodnocení funkce nervových drah. Odpověď nervového systému na podnět vyvolá vznik pohybujícího se elektrického pole, které dokážeme snímat [1]. Zrakovými evokovanými potenciály se testuje zraková dráha pomocí dráždění fotoreceptorů sítnice definovaným zrakovým podnětům. Na toto měření se používají buď strukturovaný (šachovnice) nebo zábleskový podnět. Strukturovaný podnět aktivuje optický systém efektivněji. Dráždění zrakových drah pomocí záblesků není diagnosticky až tak významné. Zrakové evokované potenciály se používají například



Obrázek 2.1: Graf zvukových evokovaných potenciálů zaznamenaných ze středního okcipitálního skalpu.


na diagnostiku roztroušené sklerózy nebo traumaticky poškozených nervů. Příklad zvukového evokovaného potenciálu lze vidět na obrázku 2.1.

2.1.2 Sluchové evokované potenciály

Sluchové evokované potenciály slouží k diagnostice periferního sluchového nervu pomocí zvuku, generovaného z vnějšího prostředí, který směřuje pomocí sluchové dráhy ze šneka do mozkové kůry.

AEP jsou velmi malé elektrické napěťové potenciály pocházející z pokožky hlavy, které jsou vyvolávány pomocí nějakých sluchových podnětů, jakými jsou různé tóny, zvuky, řeč apod.

ERP (viz výše) jsou reakce mozku, které jsou vysílány na základě nějaké "události"(eventu) - v případě AEP se jedná o zvuk, resp. o jednoduché opakované cvaknutí vysílané do jednoho ucha přes sluchátko. Druhé ucho, které není vyšetřováno, je blokováno maskovacím šumem [1]. Výhodou AEP ve srovnání s jinými diagnostickými metodami pro stanovení poškození sluchu spočívá právě v její větší objektivnosti. Příklad sluchového evokovaného potenciálu lze vidět na obrázku 2.2.



Obrázek 2.2: Graf sluchových evokovaných potenciálů na kanálu Fz.

2.1.3 Somatosenzorické evokované potenciály

Somatosenzorické evokované potenciály se stávají ze série vln popisujících postupnou aktivaci nervových struktur podél somatosenzorických drah. Lze je vyvolávat mechanickou stimulací, avšak mnohem větší a silnější odezvu lze získat elektrickou stimulací periferních nervů. Obecně metoda SEP tedy vyhodnocuje zdravotní stav periferních nervů a míchy. Dále také testuje, jak mícha nebo mozek přenáší informace o smyslových podnětech. Je možné pomocí metody SEP lokalizovat, přesně ve kterém místě došlo k blokaci signálu a jestli je problém v přenosové soustavě (periferní nervy), či v interpretačním centru (mozek, mícha) [1].

2.1.4 Motorické evokované potenciály

Motorické evokované potenciály jsou zaznamenávány ze svalů po stimulaci motorického kortexu (magnetické nebo elektrické).

Motorické evokované potenciály jsou indukovány pomocí transkraniální magnetické stimulace a mohou proto sloužit jako index tzv. "premovement neuronal activity"[1].

3 Pohyb v EEG

Pro detekci pohybu (například nějaké končetiny) se v EEG používají tzv. kognitivní evokované potenciály (ERP), ke kterým lze přiřadit Bereitschaftspotential (BP, přípravný motorický potenciál)[2, 9, 15]. V naměřených datech se nachází synchronizace a desynchronizace spektrálních vlastností EEG (tzv. ERD/ERS). Pomocí ERD/ERS lze teoreticky poznat, zda subjekt myslel na pohyb nějaké své končetiny a při tom pohyb skutečně nevykonal.

3.1 Kognitivní evokované potenciály


Při měření kognitivních evokovaných potenciálů subjekt pohodlně sedí nebo leží. Je přesně instruován vyšetřujícím, nejlépe ještě před měřením, jaký konkrétní pohyb má vykonat a kdy přesně ho má vykonat.

Snímací elektrody, umístěné ve speciální EEG čepici, se řídí standardním systémem 10-20¹. Počet registrovaných elektrod je limitován počtem kanálů, které jsou k dispozici na registrujícím přístroji. Nejčastější používané kanály pro kognitivní evokované potenciály jsou Cz, C3, C4, Fz, Pz, P3, P4. Který konkrétní kanály se ve finále použijí, záleží především na tom, jakou částí těla daný subjekt hýbal. Dále je za potřebí umístit referenční elektrodu, která může být jakoukoli elektrodou na speciální čepici EEG čepici. Další možností kam umístit referenční elektrodu je ušní lalůček. Zemní elektrodu je velmi vhodné umístit na končetinu, s níž se pohybuje a to nejlépe v místě, kde vzdálenost ke kosti je nejmenší. Příklad kognitivních evokovaných potenciálů lze vidět na obrázku 3.1 [1].

3.2 Přípravný motorický potenciál

Přípravný motorický potenciál (Readiness Potential nebo Bereitschaftspotential) byl popsán v polovině 60. let 20. století Kornhuberem a Deeckem jako Bereitschaftspotential. Tento potenciál začíná nabíhat přibližně asi o 1 sekundu před tím, než si vyšetřovaný subjekt uvědomí, že chce provést

¹Obvod hlavy je rozdělen na úseky po 10% a po 20%. Podobným způsobem probíhá rozměření ve zbývajících dvou kolmých rovinách. Výsledkem je síť bodů, podle které jsou pak umísťovány elektrody na standardní místa. Elektrody, které jsou umístěné vpředu hlavy, nazýváme prefrontální, za nimi se nachází řada frontálních elektrod, poté následují centrální elektrody, dále parietální elektrody a úplně vzadu okcipitální elektrody. Strany jsou osazeny temporálními elektrodami.



Obrázek 3.1: Graf kognitivních evokovaných potenciálů.

pohyb. Z toho důvodu BP souvisí s vědomými i nevědomými aktivitami. Může být ovlivňován řadou fyzikálních i psychologických parametrů a také nepředchází jen pohybu, který byl subjektem vykonán, ale i pohybu, jenž nebyl subjektem proveden, tudíž souvisí velmi úzce s kognitivní aktivitou vázanou na pohyb.

Tento potenciál je získáván zprůměrováním EEG signálu, který je spuštěn opakovaným pohybem (většinou jednoduchým jako například pohyb prsu, ruky, nohy). Výsledek je reprezentován křivkou skládající se z několika částí, které má v podstatě každý autor jinak pojmenované. Nejčastěji však pro první část křivky, která začíná 1500-800 milisekund a končí přibližně 500 milisekund před začátkem pohybu, se označuje jako BP1. Druhá část navazuje na první část a končí asi 50 milisekund před začátkem pohybu. Tato druhá část se nazývá BP2 nebo také NS (negative shift). Těsně před začátkem pohybu může být do BP2 vepsána krátká pozitiva - PMP (premovement potential). Ta je nekonzistentní. Fyziologický význam jednotlivých komponent nebyl nijak objasněn [1].


3.3 Event-related synchronization a Event-related desynchronization

Od Bergera (1930) je známo, že určité události mohou zablokovat nebo desynchronizovat probíhající činnost alfa. Tyto typy změn jsou časově uzamčeny pro událost, ale nejsou fázově uzamčeny, a proto nemohou být extrahovány jednoduchou lineární metodou, ale mohou být detekovány frekvenční analýzou nebo Fourierovou transformací. To znamená, že tyto události související s jevy frekvenční specifikace změn probíhající EEG aktivity mohou obecně spočívat buď v poklesu, nebo zvyšování výkonu v daných kmitočtových pásmech. Může to být považováno za pokles nebo zvýšení synchronizace základních populací neuronů.

První případ se nazývá Event-related desynchronization nebo také ERD a druhý případ Event-related synchronization, takzvané ERS. Samozřejmě ERD a ERS jevy se vyskytují nejen u EEG, ale také u MEG záznamů. Na rozdíl od tradičních ERPs, které lze považovat za řadu přechodných postsynaptických reakcí vyvolané specifickým stimulem, ERD/ERS jevy mohou být považovány za změny v jednom nebo více parametru, které řídí oscilace v síti neuronů [4, 8, 11, 13] (viz obr. 3.2)

Měli bychom také uvést, jaké jsou obecné vlastnosti těchto kmitů. Druhy hlavních faktorů určujících vlastnosti oscilací EEG:

1. Vlastnosti vnitřních membrán neuronů a dynamika synaptických pro-



Obrázek 3.2: Schéma pro generování indukovaných (ERD/ERS) a evokovaných (ERP), přičemž první je vysoce specifická pro frekvenci.

cesů.

2. Pevnost a rozsah propojení mezi síťovými prvky, nejčastěji vytvořené zpětnovazebními smyčkami. Různé druhy zpětnovazebních smyček lze rozlišit. Buď zahrnují thalamo-kortikální nebo kortiko-kortikální na krátké nebo na dlouhé vzdálenosti.
3. Modulační účinky z obecných nebo lokálních neurotransmiterních systémů.

Neuronové sítě mohou zobrazovat různé stavy synchronizace s oscilacemi na různých frekvencích.

3.3.1 Kvantifikace ERD/ERS v čase

Jedním ze základních rysů měření ERD/ERS je, že výkon EEG/MEG v rámci identifikovaných kmitočtových pásem je relativně zobrazen na spektrální výkonové hustotě stejných EEG/MEG zaznamenaných během stimulačního nebo klidového období několik sekund před nastávajícím stimulem (v našem případě pohybu ruky). Vzhledem k tomu, že změny související s událostí v probíhajícím EEG/MEG vyžadují čas na vývoj a obnovu, zejména pokud jde o rytmy alfa pásma, interval mezi dvěma po sobě jdoucími událostmi by měl trvat nejméně několik sekund.

Klasická metoda (označme ji metodou 1) pro výpočet časového průběhu ERD/ERS zahrnuje následující kroky:

1. Vyjmutí epochy související s pohybem a pásmová filtrace dat v epoše.
2. Výpočet druhé mocniny hodnot vzorků v epoše
3. Průměrování souvisejících epoch
4. Vyhlazení zprůměrovaných vzorků

Tento postup má za následek změnu časového průběhu hodnot výkonu pásma. Při použití klasické (metody 1) může dojít k tomu, že evokovaný potenciál, který vznikl před vykonáním pohybu, může výrazně ovlivnit pokles výkonu ERD. To lze odstranit použitím následující metody:

1. Filtrování přes pásmo.
2. Výpočet rozptylu dat mezi testy.
3. Zprůměrování v čase

Rozdíl mezi oběma výpočetními postupy ERD/ERS popsal Kalcher a Pfurtcheller (1995). Bylo zjištěno, že v případě složek s nižší frekvencí (dolní alfa a theta pásma) může fázově blokový nárůst výkonu v důsledku ERP maskovat nepoužívaný pokles ERD při použití klasické metody pro výpočet časového průběhu ERD.

Pro získání procentních hodnot pro ERD/ERS je výkon v rámci sledovaného kmitočtového pásma v čase po události daný hodnotou A , zatímco hodnota v čase před událostí je dána R . ERD nebo ERS je definována jako procentní podíl snížení výkonu nebo zvýšení podle příslušných výrazů:

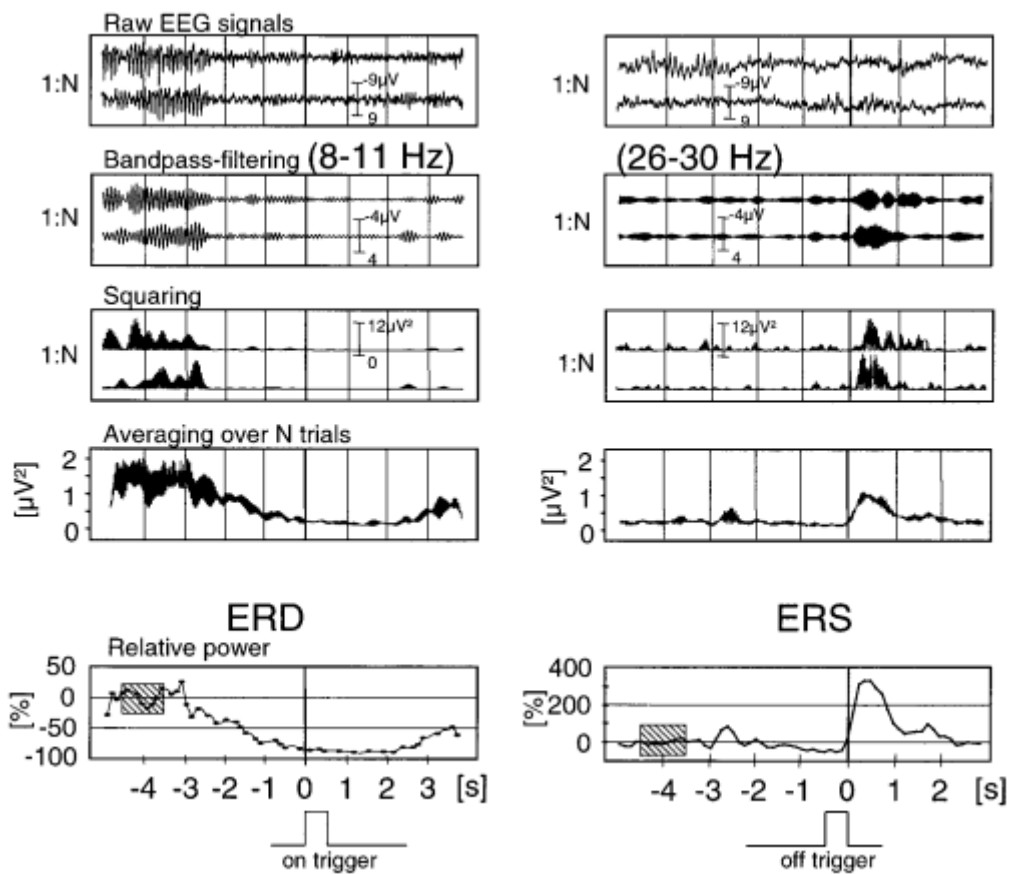
$$ERD = \frac{R - A}{R} 100 \quad (3.1)$$

$$ERS = \frac{A - R}{R} 100 \quad (3.2)$$


Celkový postup výpočtu ERD/ERS je zobrazen na obrázku 3.3 s jedním příkladem dominantního ERD v alfa pásmu na levé straně a jedním příkladem s dominantním ERS v pásmu beta na pravé straně [13].

3.3.2 Prostorové mapování ERD/ERS

Vícekanálové EEG signály jsou obvykle zaznamenávány proti běžné referenční elektrodě. Data jsou tedy závislá na poloze referenční elektrody. Pro přepočtení EEG dat závislých na referencích jsou k dispozici různé metody podrobně popsané Lopesem da Silvou et al. (1993), Pfurtcheller (1992).



Obrázek 3.3: Princip zpracování ERD(levá strana) a ERS (pravá strana). Snížení výkonu pásma signalizuje ERD a zvýšení výkonu pásma ERS



Obrázek 3.4: Distribuce ERD vypočtená před pohybem pravé ruky. Mapy jsou zobrazeny shora. (a) Spline surface Laplacian vypočítaná na realistickém modelu hlavy. (b) Spline surface Laplacian vypočítaná na modelu sférické hlavy a zobrazená na realistickém modelu hlavy. (c) Výsledky lineárního odhadu založené na realistickém modelu hlavy. (d) Výsledky lineárního odhadu založené na modelu sférické hlavy a zobrazené na realistickém modelu hlavy.

Mapy bez referencí obecně vykazují ve srovnání s referenčními mapami více ohniskových vzorů a jsou zvláště doporučovány, když jsou analyzována data odpovídající pohybovému úkoly.

Pro prostorové mapování ERD/ERS jsou k dispozici různé metody, jako je například výpočet povrchového napětí, kortikálního zobrazování a zobrazování s distribuovaným zdrojem. Na obr. 3.4 je znázorněn příklad ERD map vypočtených pomocí několika metod před pohybem pravé ruky. Jak je vidět, s těmito různými metodami existují pouze okrajové rozdíly v místě zaměření ERD [13, 16].

4 Klasifikace pohybu v EEG

EEG signál měřeného subjektu lze rozdělit do epoch a z těch následně dle výše uvedených postupů vypočítat procentní podíl snížení nebo zvýšení výkonu (ERD/ERS). ERD i ERS je tedy možné si představit, jako vektor který obsahuje právě tolik položek jako daná epocha milisekund. Nejjednodušší možný způsob jak připravit EEG data ke klasifikaci je vytvořit vektor stejně velký jako součet velikostí vektorů ERD a ERS. Následně do vytvořeného vektoru nejprve nahrát vektor ERD a poté za něj umístit vektor ERS. Tímto poměrně jednoduchým způsobem lze vytvořit příznakový vektor, který je možné použít ve většině klasifikátorů. Poslední otázkou tedy zůstává, jaký klasifikátor nejlépe zvolit pro nejlepší úspěšnost klasifikace.

4.1 Umělé neuronové sítě

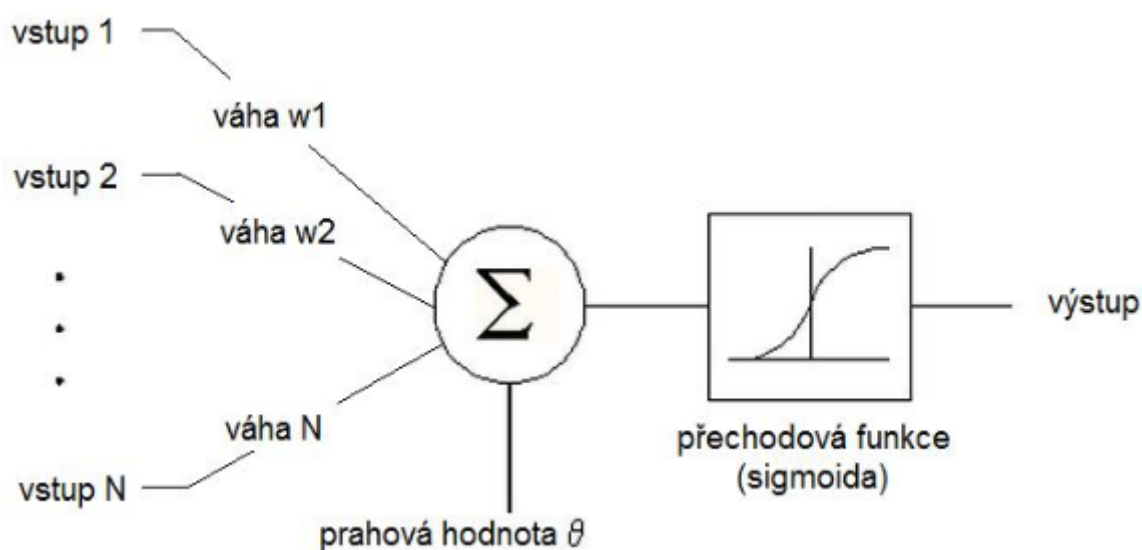
Umělé neuronové sítě jsou jedním z hlavních nástrojů používaných ve strojovém učení. Jak naznačuje "neurální" část jejich jména. Jsou to systémy inspirované mozkiem, které mají replikovat způsob, jakým se lidé učí. Neuronové sítě se skládají ze vstupních, výstupních a především skrytých vrstev, které transformují vstup ze vstupní vrstvy na něco, co může výstupní vrstva použít.

Umělé neuronové sítě se stávají z více neuronů (příklad modelu takového neuronu lze vidět na obrázku 4.1), které napodobují biologické neurony lidského mozku. Do každého neuronu vede N vstupů. Ty lze chápat jako výstup z jiných neuronů. Neuron obsahuje prahovou hodnotu (neboli potenciál neuronu), při jehož překonání je neuron nabuzen a vysílá signál na výstup ve formě přenosové funkce (např. sigmoida nebo hyperbolická tangenta). Výstup z každého neuronu se nazývá jeho aktivací nebo hodnotou neuronu. Neurony jsou spojeny vazbami a vzájemně se ovlivňují. Každé vazbě mezi neurony je přidělena váha.

Umělé neuronové sítě jsou schopny se učit, což se děje změnou hodnot vah. Na obrázku 4.2 lze vidět strukturu jednoduché neuronové sítě.

4.1.1 Typy umělých neuronových sítí

Existují dvě topologie umělých neuronových sítí a to FeedForward a Feedback.



Obrázek 4.1: Příklad struktury jednoho neuronu podle matematického modelu nazývaného perceptron. Lze vidět více vstupů, které mají různou váhu.

V umělých neuronových sítích konstruovaných pomocí topologie Feed-Forward je tok informací jednosměrný. Jednotka odesílá informace do jiné jednotky, ze které nedostává žádné informace. Neexistuje žádná zpětná vazba mezi neurony. Používají se při generování vzorů, rozpoznávání či klasifikaci. Oproti tomu topologie FeedBack umožňuje zpětnou vazbu mezi neurony a používá se v obsahu adresovatelných pamětí (tzv. asociativních pamětí).


4.1.2 Strojové učení umělých neuronových sítí

Umělé neuronové sítě jsou schopny se učit a musí být natrénovány na nějaké trénovací množině dat. Existuje několik možností jak učit neuronovou síť.

Učení s učitelem

Neuronová síť se učí porovnáváním aktuálního výstupu s požadovaným výstupem (učitel) a snaží se nastavit váhy vazeb tak, aby se snížil rozdíl mezi aktuálním a požadovaným výstupem. Mezi metody učení s učitelem patří například metoda Backpropagation.

Backpropagation je jedna z možností pro jemné vyladění vah v umělé neuronové síti na základě chybovosti získané v předchozím období (nebo také iteraci). Váhy se aktualizují za pomoci klesání gradientu. Vypočítá se gradient chybové funkce s ohledem na nastavené váhy v neuronové síti. Celý



Obrázek 4.2: Struktura jednoduché umělé neuronové sítě, která obsahuje jednu vstupní, výstupní a skrytou vrstvu. Kolečka představují neurony, což tedy znamená, že vstupní vrstva má jeden neuron, skrytá vrstva 5 neuronů a výstupní vrstva 2 neurony. Šipky mezi neurony představuje vazby (také synapse).

výpočet probíhá zpětně sítí a lze jej definovat následující rovnicí.

$$*W_x = W_x - a\left(\frac{\delta Error}{\delta W_x}\right) \quad (4.1)$$

$*W_x$ je výsledná nová váha. W_x je stará váha. a značí míru učení a na konec v srdci celého algoritmu backpropagation je výraz pro parciální derivaci $\delta Error/\delta\omega$ chybové funkce Error s ohledem na jakoukoli váhu ω v neuronové síti. Výraz nám říká, jak rychle se cena změní, když změníme váhy. Proto backpropagation není jen rychlý algoritmus pro učení, ale ve skutečnosti nám dává detailní pohled na to, jak změna váhy mění celkové chování neuronové sítě.


Například, pro aktualizaci váhy W_6 vezmeme W_6 a odečteme parciální derivaci chybové funkce s ohledem na W_6 . Volitelně násobíme derivaci chybové funkce vybraným číslem (míra učení), abychom se ujistili, že nová aktualizovaná váha minimalizuje chybovou funkci.

Učení bez učitele

Váhy vazeb se nastavují tak, aby výstup umělé neuronové sítě byl konzistentní, tj. aby síť poskytovala stejnou odezvu při totožných, popřípadě velmi podobných vstupních příznakových vektorech.

5 Návrh postupu na detekci pohybu ruky v EEG záznamech

Ze všeho nejdříve, abychom mohli vůbec získat nějaká EEG data, je třeba vytvořit vhodný scénář pro měření EEG, ze kterého následně budeme tvořit ERD/ERS. Po vytvoření vhodného scénáře můžeme přejít k samotnému měření. Jelikož klasifikujeme pomocí neuronové sítě, je třeba naměřit velký počet dat, abychom měli dostatečně velkou trénovací a klasifikační množinu dat. Po získání všech naměřených EEG záznamů je třeba tyto data upravit na ERD/ERS a poté je převést na příznakové vektory, aby je klasifikátor mohl zpracovat. Samotná klasifikace poté probíhá pomocí jednoduché neuronové sítě, která obsahuje dvě skryté vrstvy. Celý postup lze přehledně vidět na obrázku 5.1.



Obrázek 5.1: Diagram pro postup detekce pohybu ruky v EEG. Prvním krokem je návrh scénáře, aby poté mohlo být zrealizované měření. Následně je zpracování nebo také příprava dat pro klasifikaci. Posledním krokem je samotná klasifikace.

6 Návrh scénáře pro měření EEG

Celý scénář pro měření EEG se stává z osmi cyklů, kde každý cyklus obsahuje klidovou a stimulační fázi. Při zahájení jednotlivých cyklů se subjekt nachází v klidové fázi, která trvá jednu minutu, kde má za úkol sedět pokud možno nehybně. To znamená i s minimem mrkání, pokud má otevřené oči. Po klidové fázi subjekt přejde do stimulační fáze, která trvá 2 minuty, kde subjekt hýbe nebo si představuje pohyb zápěstím na levé, či pravé ruce. Když je subjekt ve stimulační fázi provádí úkol po pěti sekundovém intervalu. Na přechod mezi jednotlivými fázemi je subjekt upozorněn zelenou diodou umístěnou před ním. Pokud dioda svítí, subjekt se nachází ve stimulační fázi a vykonává danou úlohu. Pokud dioda nesvítí, subjekt se nachází v klidové fázi. Tímto způsobem se jednotlivé fáze střídají a každá z nich se opakuje třikrát. Z toho vychází, že každý tento cyklus trvá přesně 9 minut.

Jak už bylo výše zmíněno, celé měření se skládá z osmi cyklů. Jednotlivé cykly se od sebe liší pouze a jenom tím, že subjekt provádí jinou činnost ve stimulační fázi, popřípadě je to zkombinované s otevřenými, či zavřenými oči. Takto vypadají jednotlivé cykly:

1. Pohyb levou rukou s otevřenými oči.
2. Pohyb levou rukou se zavřenými oči.
3. Představa pohybu levou rukou s otevřenými oči.
4. Představa pohybu levou rukou se zavřenými oči.
5. Pohyb pravou rukou s otevřenými oči.
6. Pohyb pravou rukou se zavřenými oči.
7. Představa pohybu pravou rukou s otevřenými oči.
8. Představa pohybu pravou rukou se zavřenými oči.

Příprava subjektu na měření, počínaje vysvětlením jednotlivých cyklů, až po řádné připevnění elektrod, trvá přibližně 10 minut. Proto celý průběh měření za použití výše uvedeného scénáře trvá něco okolo 90 minut.

7 Měření EEG

Měření probíhalo celkem na patnácti lidech, z toho jenom dvanáct lidí absolvovalo kompletní výše navržený scénář. Abychom měli lepší výsledky z klasifikátoru, používáme jen kompletní naměřená data. Z kompletně naměřených lidí bylo šest mužů a šest žen. Muži byli ve věkovém rozmezí 21-26 let a ženy byly ve věkovém rozmezí 18-23 let.

Každému měřenému subjektu bylo před zahájením měření vysvětleno přesně, jak celé měření bude probíhat a před každým cyklem konkrétně řečeno jak další cyklus bude probíhat. Mezi tím zdravotní sestřička upevnila subjektu na hlavu speciální EEG čepici, která je osazena elektrodami Ag/AgCl odpovídající systému rozmístění elektrod 10-20. Poté připevnila subjektu na ruku 2 elektrody a jednu zemnicí elektrodu těsně pod loket, protože tam je vzdálenost od kosti nejmenší. Na konec byla připevněna referenční elektroda na ušní lalůček.

Po dokončení přípravy byl subjekt umístěn do temné zvukotěsné komory, aby v průběhu měření nebyl vyrušován žádnými okolními vlivy. Před zavřením této komory byl na všech elektrodách zkontrolován odpor, aby byl menší než $5K\Omega$. Po této kontrole následovalo jen rychlé připomenutí, co subjekt má provádět ve stimulační fázi. Následně začalo měření prvního cyklu. Po každém cyklu se otevřeli dveře od komory a vysvětlilo se subjektu, co přesně má dělat v dalším cyklu. Občas mezi jednotlivými cykly potřeboval subjekt pěti minutovou pauzu, protože každý cyklus je velmi náročný jak po stránce fyzické, tak po stránce psychické.

Po skončení posledního cyklu každý subjekt obdržel cca pěti stránkový dotazník pro získání několika základních údajů.

7.1 Použitá technika pro měření

Pro záznam EEG dat byl použit Brainvision recorder, což je multifunkční, mimořádně univerzální a snadno použitelná softwarová platforma pro nastavení záznamu EEG a je kompatibilní se všemi zesilovači firmy Brain Products. Každý záznam EEG uložený tímto softwarem se ukládá do tří jednotlivých, na sobě závislých souborů. Jedná se o soubory *.eeg, *.vhdr a *.vmrk. Soubor *.vhdr má v sobě uložena všechna důležitá nastavení z měření. To znamená například počet kanálů a jejich označení, interval vzorkování (bylo použito vždy 1 KHz) nebo v jakém datovém typu se ukládají EEG data (například INT_16). Je důležité také zmínit, že tento soubor odkazuje na zbylé

Počet kanálů	32
Vstupní impedance	Přepínatelný: 10 MOhm/10 GOhm (pro DC)
Dolní mezní frekvence	0Hz v režimu DC nebo 0,016 Hz/10 s v režimu AC
Typ filtru	Filtr prvního řádu s 6dB/oktávou
Vzorkovací frekvence	5kHz na kanál
Přenos signálu	Opticky propojené pomocí duplexních optických kabelů


Tabulka 7.1: Seznam parametrů zesilovače BrainAmp DC

dva soubory. Soubor *.vmrk ukládá všechny zaznamenané značky (markry), podle kterých se budou dále hledat epochy. V našem případě existují čtyři druhy značek, které jsou označeny čísly 1, 2, 4 a 8. Značka označená číslem 1 se nachází v klidové fázi, obdobně číslo 2 značí, že se značka nachází ve stimulační fázi. Číslo 4 značí začátek klidové fáze a na konec značka s označením 8 udává konec klidové fáze. Poslední soubor *.eeg je binární a uchovává všechny eeg data ze všech měřených kanálů. Proto po pouhých devíti minutách záznamu velikost tohoto souboru dosahuje přes 20MB.

Dále byl použit zesilovač BrainAmp DC od firmy brain products. BrainAmp DC obsahuje všechny vynikající funkce zesilovače BrainAmp s přidáním režimu záznamu DC a možností vícenásobného filtrování. Nastavení zesilovače je plně ovladatelné přes nahrávací software. Je také možné přepnout z režimu nahrávání z DC na AC a také vybrat různé šířky pásma. V tabulce 7.1 jsou uvedeny některé z parametrů zesilovače. EEG zesilovač produkuje jednotlivé značky na základě EEG signálu.

Další část je mikrokontrolerová deska firmy STM s označením STM324F429I-DISCO viz obrázek 7.1. Ta je vybavena 256KB RAM pamětí, 2MB Flash pamětí a především dotykovým displejem, který slouží například k zapnutí měření či nastavení parametrů scénáře. Na tomto displeji lze vidět tři záložky nazvané jako Start, Pulse & Trhreshold a Scenario param. Záložka Start slouží k zapnutí či vypnutí měření. Lze na ní vidět, v jaké fázi se právě měření nachází a je možné pozorovat průběh EMG, kde je možnost si zobrazit aktuální nastavování prahu, podle právě probíhající klidové fáze viz obrázek. Ve druhé záložce je možné si nastavit například klidový či stimulační synchronizační puls nebo neaktivní čas po pohybu viz obrázek. Tento čas slouží k tomu, pokud subjekt hýbne rukou a poté do nastaveného času hýbne znovu, aby se druhý pohyb nezaznamenal. Poslední záložkou je Scenario param. kde si lze nastavit dobu trvání stimulační/klidové fáze, počet stimulací a též vzorkovací frekvenci. Na této STM desce je realizovaný celý vlastní vytvořený scénář.

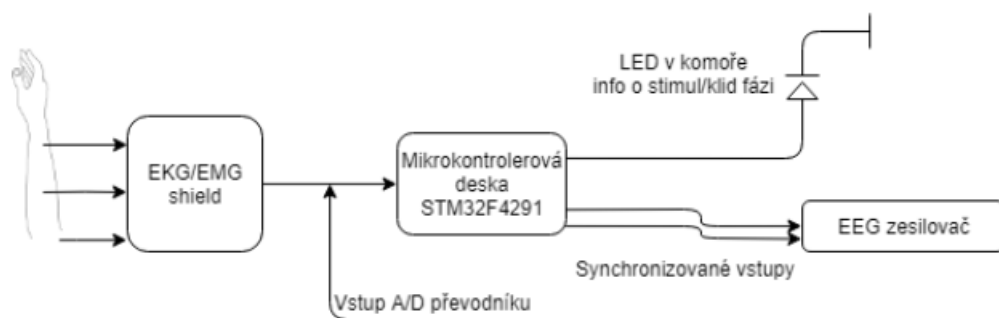
K mikrokontrolerové desce je připojen EKG/EMG shield od firmy Olimex



Obrázek 7.1: Mikrokontrolerová deska STM324F429I-DISCO a EKG/EMG shield od firmy Olimex.

(viz obrázek 7.1). Výstupem z EKG/EMG shieldu je analogový signál, který je převeden na A/D převodník výše zmíněné desky STM.

Kompletní zapojení je možné vidět na obrázku 7.2.



Obrázek 7.2: Schéma zapojení jednotlivých komponent pro měření. Tři šipky, které vedou z ruky, značí zapojení tří elektrod z toho ta nejnižše nakreslená je uzemňovací elektroda.

8 Příprava dat pro klasifikaci

Příprava dat pro umělou neuronovou síť je naimplementována v programovacím jazyce Python za pomoci modulu MNE, který je přímo určený pro zpracování, vizualizaci a analýzu lidských neurofyziologických dat. S využitím tohoto modulu se tedy velice usnadní práce s EEG daty. Jediná nevýhoda MNE je nepřehlednost velice obsáhlé dokumentace.

Ze všeho nejdříve je třeba si vytvořit pole pro vstupní EEG data, protože načítáme více než jeden soubor. Poté stačí jednoduše načíst data ze souborů tak, že vytvoříme cyklus, který postupně načte soubor po souboru například příkazem `eeg.append(mne.io.read_raw_brainvision("cesta_k_souboru"))`. Po tomto načtení je třeba naimportovat tyto data do MNE příkazem `eeg[i].load_data()`. Příklad načtených dat lze vidět na obrázku 8.1.


Jelikož ze stejných dat vytváříme ERD i ERS, je třeba z načtených dat vytvořit jednu kopii, abychom mohli s daty pracovat zvlášť pro ERD a zvlášť pro ERS. Tato kopie lze jednoduše vytvořit příkazem `ers=eeg[i].copy()`.

8.1 výpočet ERD

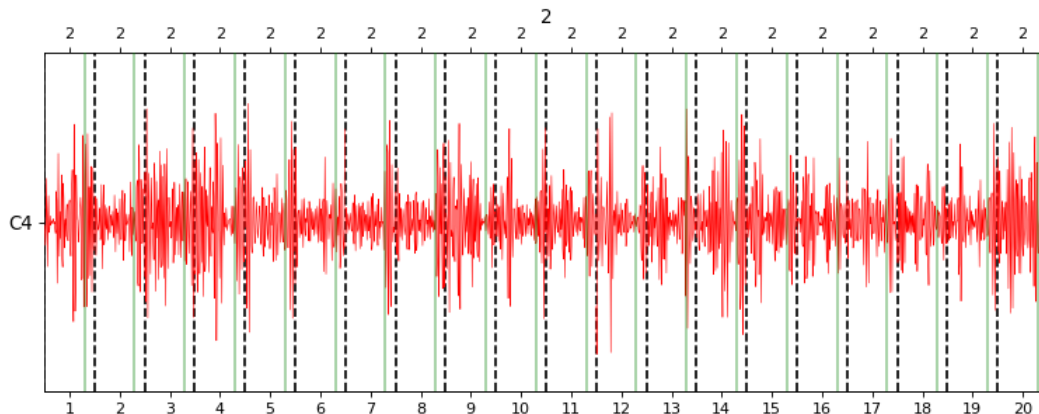
Pro výpočet ERD je nejprve nutné vyfiltrovat vstupní EEG data podle frekvence, protože ERD se nachází ve frekvencích od 8Hz do 12 Hz. To lze provést příkazem `eeg[i].filter(8,12,fir_design="firwin")`. Na obrázku 8.2 lze pozorovat vyfiltrovaná data z obrázku 8.1 pro ERD.

Po výše uvedené filtraci je nutné tyto filtrovaná data umocnit na druhou. To lze zrealizovat funkcí `eeg[i].apply_function(square)`. Bohužel funkce `apply_function()` umí volat jakékoli funkci pouze bez parametrů. Z toho důvodu jsem si udělal vlastní jednoduchou funkci pojmenovanou `square()`, která jediné co udělá je, že provádí příkaz `eeg=np.power(eeg,2)` a vrací výsledná umocněná data na druhou. Graf těchto umocněných dat můžete vidět na obrázku 8.3.


Dalším krokem ve výpočtu ERD je nalézt epochy v těchto datech. To lze provést příkazem `epochsERD.append(mne.Epochs(eeg[i], mne.find_events(eeg[i]), event_id=id, tmin=-2.0, tmax=0.5, baseline=None, preload=True, picks=chan))`. Parametr Event id se mění podle toho, zda hledáme epochy v klidové nebo stimulační fázi. Pro epochy v klidové fázi se `id=1` a pro epochy ve stimulační fázi se `id=2`. Parametry `tmin` a `tmax` určují, v jaké době od epochy se mají brát data s tím, že nalezená epocha je v čase 0. Dalším důležitým



Obrázek 8.1: Graf EEG signálu pro kanál C4, který je rozdělen do různých epoch. Lze vidět prvních dvacet epoch ze stimulační části jednoho souboru. Po levé straně grafu je označení použitého kanálu. Pod grafem je očíslování jednotlivých epoch a nad grafem lze vidět ID epoch. Jelikož je vybrána stimulační část, tak všechny epochy mají ID 2. Dále lze na grafu pozorovat přerušovanou čáru, která označuje konec jednotlivých epoch a zelenou čáru, která označuje začátek pohybu.



Obrázek 8.2: Graf vyfiltrovaného EEG signálu (8Hz-12Hz) pro kanál C4, který je rozdělen do různých epoch. Lze vidět prvních dvacet epoch ze stimulační části jednoho souboru. Graf je stejně strukturován jako na obrázku 8.1, pouze obsahuje jiná data.



Obrázek 8.3: Graf vyfiltrovaného a umocněného EEG signálu pro kanál C4. Osa y uvádí sílu zobrazeného signálu a osa x čas, který je nastavitelný parametry t_{min} a t_{max} . Lze také spatřit přerušovanou čáru v čase 0.0, která udává počátek pohybu. Je možné si všimnout, že po umocnění signálu signál neobsahuje žádná data, která jsou menší než 0.

parametrem je baseline, kterou je nutno nastavit na none. Kdybychom nastavili jinou baselinu nebo parametr úplně smazali (což znamená, že bude nastavena defaultní baselina), umocněná data by se přizpůsobila baselině a mohla by obsahovat záporné hodnoty, což je určitě špatně. Poslední důležitý parametr je picks, který říká, jaké kanály mají být vybrány. Pohyb pravou rukou ovlivňuje především levou část mozku konkrétně kanál C3, proto když pracujeme s daty, kdy subjekt hýbal pravou rukou je vybírán pouze kanál C3. Ve druhé skupině dat subjekty dělaly pohyb levou rukou, který oproti pohybu pravou rukou aktivuje především pravou část mozku konkrétně kanál C4, tak v těchto případech je vybírán kanál nastaven pouze na C4.

Předposledním krokem, který je nutný pro výpočet ERD je zprůměrování výše uvedených epoch (viz obrázek 8.4). Tento krok lze udělat jednoduchým příkazem `epochsERD[i]=epochsERD[i].average()`, který všechny epochy zprůměruje.


Poslední krok k získání ERD (viz obrázek 8.5) je aplikace následující rovnice:

$$ERD_i(\%) = \frac{Act_i - R}{R} 100 \quad (8.1)$$

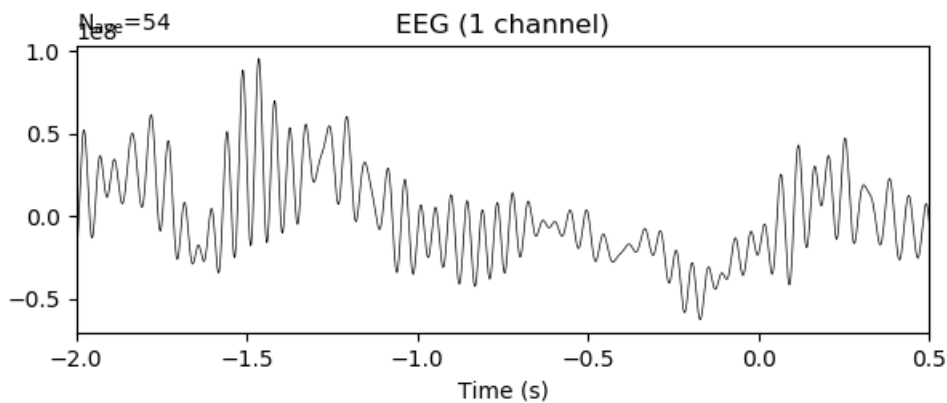
Act představuje výše zprůměrované epochy a R lze spočítat pomocí následující rovnice:

$$R = \frac{1}{k+1} \sum_{i=r_0}^{k+r_0} Act_i \quad (8.2)$$

Podle uvedené rovnice lze říct, že R je zprůměrování hodnot v intervalu $[r_0, r_0+k]$, což je stejný interval, který je definován parametry t_{min} a t_{max} .



Obrázek 8.4: Tento graf ukazuje zprůměrované všechny epochy, které byly dříve vyfiltrovány a umocněny. Osa x značí čas, který je definován parametry t_{min} a t_{max} . Osa y znázorňuje sílu signálu. Číslo N umístěné vlevo nad grafem ukazuje, kolik epoch bylo celkem zprůměrováno.



Obrázek 8.5: Tento graf je na první pohled naprosto totožný s obrázkem 8.4. Ovšem při bližším prozkoumání si lze všimnout, že data jsou normalizovaná pomocí rovnice 8.1 a proto data se pohybují pouze v intervalu $\langle -1;1 \rangle$. Je možné vidět jak data, přibližně v čase -1,5, mají tendenci klesat až do času přibližně -0,2 a poté stoupat ještě před pohybem ruky. Takto by mělo vypadat výsledné ERD každého měřeného subjektu, který dopodrobna plnil veškeré instrukce.

8.2 výpočet ERS

Postup výpočtu ERS je skoro totožný jako postup výpočtu ERD, proto nebudu v tomto postupu zacházet do příliš velkých detailů. Abychom byli schopni vypočítat ERS je opět nutné data vyfiltrovat podle frekvence. Jelikož se ERS nachází ve frekvencích od 14Hz do 22Hz, budeme tedy data filtrovat stejným příkazem jako ve výpočtu ERD, ovšem s trochu jinými parametry. Výsledný příkaz vypadá tedy asi takto: `eeg[i].filter(14,22,fir_design="firwin")`.

Po filtraci dat je postup už naprasto totožný s postupem pro ERD. To znamená, že všechny data nejprve umocním na druhou. Následně vyhledám všechny epochy, které poté zprůměruji. Na konec už zbývá jen aplikovat výše uvedené rovnice a výsledkem je ERS.

8.3 Tvorba příznakových vektorů

Je možné si výsledné ERD/ERS představit jako dva vektory. Se stejným nastavením parametrů t_{min} a t_{max} výše uvedených bude velikost každého z těchto vektorů rovna 2501 položkám. Existuje mnoho způsobů jak ze dvou vektorů udělat příznakový vektor, jako například oba vektor sečíst a udělat z něj pouze jeden. Ovšem z obavy, že při nějaké takové operaci ztratím nějaké charakteristické rysy buď ERD nebo ERS, tak jsem se rozhodl, že příznakový vektor udělám jednoduše tak, že vytvořím prázdné pole o velikosti 5002, do kterého nahraji nejdříve vektor ERD a za něj vektor ERS. Tím vznikne jeden velký příznakový vektor. Aby bylo možno natrénovat klasifikátor (viz kapitola 9), je nutné na konec vektorů přiřadit nějaký znak, který bude značit, zda je vektor vypočítaný ze stimulační fáze či z klidové fáze. V našem případě je zvoleno číslo 1 pro stimulační fázi a číslo 0 pro klidovou fázi. Tyto výsledné vektory je program schopný zapsat do souborů, a tím je už finálně připravit na použití v klasifikátoru.

Jelikož je naměřeno celkem 12 osob, kde každá osoba při měření hýbala 2krát levou a 2krát pravou rukou, tak celkem je 48 záznamů vázaných s pohybem ruky. Z toho vyplývá, že s tímto postupem získáme 48 příznakových vektorů pro epochy v klidové fázi (ERD/ERS pro klid ruky) a 48 příznakových vektorů pro epochy ve stimulační fázi (ERD/ERS pro pohyb ruky). Jelikož jsou data od různých lidí různá a každý subjekt hýbal rukou v různých intervalech, protože nikdo netrefil přesně pěti sekundový interval, vybral jsem pro trénovací množinu 6 lidí, kteří měli nejdelší interval mezi pohyby, protože je předpokládáno, že tam bude ERD a ERS nejlepší. Tím je myšleno, že pro trénovací množinu je použito 24 vektorů z klidové fáze a 24 vektorů ze stimulační fáze. Pro klasifikační množinu je vybrán zbytek

vektori.

9 Klasifikace

Ke klasifikaci výsledných příznakových vektorů jsem zvolil jednoduchou neuronovou síť naprogramovanou také v programovacím jazyku Python s využitím modulu Keras. Keras je vysoce úroňové API pro neuronové sítě a schopný běhu nad moduly TensorFlow, CNTK nebo Theano. V našem případě běží nad TensorFlow¹ modulem. Modul Keras byl vybrán z několika důvodů, ovšem hlavní důvod je, že umožňuje poměrně snadnou a rychlou konfiguraci neuronové sítě díky uživatelské přívětivosti, modularitě a rozšiřitelnosti. Bohužel má i jednu drobnou nevýhodu a to, že není kompatibilní s verzí Pythonu 3.7 ale pouze 2.7-3.6, a proto byla celá práce programovaná ve verzi Pythonu 3.6.

Trénovací a klasifikační data jsou nahrána ze souborů `train.csv` a `test.csv` do polí, se kterými se pracuje jako se vstupní vrstvou.

Celá umělá neuronová síť je tvořena modelem `Sequential`, což je v podstatě lineární svazek vrstev. Lze si to představit jako seznam vrstev, kde každá další položka v seznamu představuje další vrstvu. Po velmi rozsáhlém testování (viz kapitola 10) byla použita síť s jednou vstupní a výstupní vrstvou a dvěma skrytými vrstvami. Byl ponechán defaultně nastavený práh `kerasem` (0.5). Je to binární neuronová síť, což znamená, že výstupní vrstva má pouze jeden neuron který rozhoduje jestli ano (klasifikováno jako pohyb) nebo ne (klasifikováno jako klid), proto na konci vektorů jsou zvoleny binární rozpoznávací znaky (0 a 1).

Ve všech skrytých vrstvách i ve výstupní vrstvě je použita sigmoidální aktivační funkce, která je definována rovnicí 9.1. Jako ztrátová funkce je použita Binary Cross-Entropy už jen proto, že je použita binární umělá neuronová síť.

$$f_s(u) = \frac{1}{1 + e^{-u}} \quad (9.1)$$

Je použit algoritmus učení `back propagation` (viz kapitola 4.1.2) s nastaveným počtem iterací² na 100.

Největším problémem bylo stanovení optimálního počtu neuronů ve skrytých vrstvách. Na základě testování (viz kapitola 10) bylo zjištěno, že nejlepší možný počet neuronů pro první skrytou vrstvu je 3 000 a pro druhou skrytou vrstvu 1 500. S tímto nastavením síť byla spuštěna stokrát a výsledky

¹TensorFlow je end-to-end open source platforma pro strojové učení.

²Lze místo iterací používat označení epochy jako například v našem zdrojovém souboru pro klasifikátor.

zprůměrovány. Přesnost klasifikátoru s tímto nastavením se pohybovala mezi 75,00%-85,42%, kde průměrná hodnota všech naměřených výsledků je rovna 79,92%. Tento interval přesnosti je určen náhodným nastavováním vah při učení umělé neuronové sítě.

10 Testování

Výsledné programy byly testovány a vyvíjeny na stolním počítači s 16GB RAM pamětí a šesti jádrovým procesorem AMD RYZEN 5 1600X s frekvencí 3,6 GHz. Oba programy jsou psané a otestované v programovacím jazyce Python verze 3.6.8.

Příprava dat pro klasifikaci byla důkladně kontrolována po každém výše zmíněném kroku postupu a bylo zkoumáno, zda se data počítají správně. Lze také ve výsledném grafu obsaženém v kapitole 8.1 pozorovat přítomnost ERD, což je náznak toho, že data jsou opravdu správně vypočtena.

Při testování umělé neuronové sítě bylo vždy jemně pozměněné její nastavení a poté síť byla vždy spuštěna stokrát a z výsledných přesností byla vybrána minimální, maximální a průměrná přesnost viz tabulka 10.

Nejprve neuronová síť byla testována pouze s jednou skrytou vrstvou, která obsahovala 250 neuronů. V tomto případě byla průměrná přesnost 76,23%. Poté byl počet neuronů zvednut na 500 a výsledná průměrná přesnost ze zvedla jen o 1,12%, tedy na 77,35%. Po tomto druhém experimentu bylo zjištěno, že problém by nemusel být jen v počtu neuronů, ale také v počtu skrytých vrstev, tak byla přidána druhá skrytá vrstva. Jelikož po přidání druhé vrstvy byl klasifikátor značně pomalejší, tak bylo klasifikováno nejprve s malým počtem neuronů v obou sítích. První nastavení pro test se dvěma skrytými vrstvami bylo takové, že první vrstva obsahovala pouhých 50 neuronů a druhá vrstva ještě menší počet 25 neuronů. Při tomto nastavení byla zjištěna minimální přesnost 68,75%, maximální 85,42% a průměrná přesnost 76,42%. Jelikož byl rozdíl mezi minimální a maximální přesností tak veliký a navíc k tomu průměrná přesnost byla dokonce menší než s jednou skrytou vrstvou, tak byl počet neuronů v jednotlivých vrstvách postupně zvedán, dokud nebylo dosaženo průměrné přesnosti skoro 80%. Určitě by šlo přesnost ještě zvýšit například konstantním počátečním nastavením vah, kde by přesnost určitě přesáhla hranici 80%.

Počet neuronů v první skryté vrstvě	počet neuronů ve druhé skryté vrstvě	minimální přesnost	maximální přesnost	průměrná přesnost
250	0	64,58%	83,33%	76,23%
500	0	70,83%	83,33%	77,35%
50	25	68,75%	85,42%	76,42%
100	50	68,75%	85,42%	77,42%
200	100	68,75%	87,50%	77,77%
500	250	70,83%	83,33%	77,35%
1 000	500	68,75%	85,42%	79,23%
2 500	1 250	75,00%	85,42%	79,90%
3 000	1 500	75,00%	85,42%	79,92%

Tabulka 10.1: Nastavované parametry neuronové sítě a jejich minimální, maximální a průměrná přesnost. Tam kde je počet neuronů ve skryté vrstvě roven 0 znamená, že dané nastavení sítě mělo pouze 1 skrytou vrstvu

11 Závěr

Práce splňuje všechny body zadání. Scénář byl úspěšně navržen po prozkoumání problematiky týkající se ERD/ERS, a poté byl zrealizován na patnácti lidech. Naměřená EEG data se povedlo převést na ERD/ERS a následně z nich vytvořit trénovací a klasifikační množinu příznakových vektorů pro klasifikaci pomocí neuronové sítě. Navržený klasifikátor (umělou neuronovou síť) se podařilo naimplementovat a vyladit tak, že dokáže klasifikovat pohyby v záznamech EEG s průměrnou přesností 79,92%.

Bylo v plánu se pokusit o klasifikaci i představy pohybu. Ovšem v takovém případě by bylo nutné převádět data na ERD/ERS a následně je klasifikovat online při průběhu měření, protože při měření, když subjekt myslel na pohyb ruky a s rukou skutečně žádný pohyb nevykonal, tak zesilovač nevygeneroval žádné značky, podle kterých by bylo možné určit, kdy daný subjekt pomyslel na pohyb. Proto kdyby tady z dat představy pohybu bylo vytvořeno ERD/ERS, klasifikátor by sice byl schopný označit určitá místa jako pohyb, ovšem nebylo by možné nijak prokázat, že to skutečně pohyb byl, tak by nebylo možné říct jak je klasifikátor úspěšný v představě pohybu.

Přesnost klasifikátoru by mohla být určitě vylepšena, například konzistentním nastavením vah nebo vylepšením scénáře. Scénář je sice navržen dobře, ale bylo by vhodné zvětšit interval mezi jednotlivými pohyby ruky z pěti sekund minimálně na deset sekund. Poté by výsledkem měření byla data o něco vhodnější pro klasifikaci pohybu pomocí ERD/ERS.

Pokud by se klasifikátor a příprava dat pro klasifikaci předělaly tak, aby je bylo možné používat online, bylo by určitě možné, navrhnou software ve VR (viz kapitola 1), kterým by bylo možné ovládat pouhou myšlenkou na pohyb levé či pravé ruky.

Přehled Zkratk

AEP	Sluchové evokované potenciály
Ag/AgCl	Označení elektrod
API	Application Programming Interface
BP	Bereitschaftspotential
EEG	Elektroencefalografie
EMG	Elektromyografie
EP	Evokované potenciály
ERD	Event-related desynchronization
ERP	Kognitivní evokované potenciály
ERS	Event-related synchronization
MEG	Magnetoencefalografie
MEP	Motorické evokované potenciály
SEP	Somatosenzorické EP
SSEP	Ustálené evokované potenciály
VEP	Zrakové evokované potenciály

Literatura

- [1] DUFEK, J. – KAŇOVSKÝ, P. *Evokované potenciály v klinické praxi*. Institut pro další vzdělávání pracovníků ve zdravotnictví, 2000. ISBN 80-701-3306-6.
- [2] FORMAGGIO, E. et al. Modulation of event-related desynchronization in robot-assisted hand performance. *Journal of NeuroEngineering and Rehabilitation*. 2013, 10, 1. ISSN 1743-0003. doi: 10.1186/1743-0003-10-24. Dostupné z: <http://jneuroengrehab.biomedcentral.com/articles/10.1186/1743-0003-10-24>.
- [3] JEON, Y. et al. Event-related (De)synchronization (ERD/ERS) during motor imagery tasks. *International Journal of Industrial Ergonomics*. 2011, 41, 5, s. 428–436. ISSN 01698141. doi: 10.1016/j.ergon.2011.03.005. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0169814111000540>.
- [4] KRAUSE, C. M. et al. Brain oscillatory EEG event-related desynchronization (ERD) and -synchronization (ERS) responses during an auditory memory task are altered in children with epilepsy. *Seizure*. 2008, 17, 1, s. 1–10. ISSN 10591311. doi: 10.1016/j.seizure.2007.05.015. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1059131107001264>.
- [5] LANA, E. P. – ADORNO, B. V. – TIERRA-CRIOLLO, C. J. An ERD/ERS analysis of the relation between human arm and robot manipulator movements. *2013 ISSNIP Biosignals and Biorobotics Conference: Biosignals and Robotics for Better and Safer Living (BRC)*. 2013, s. 1–7. doi: 10.1109/BRC.2013.6487461. Dostupné z: <http://ieeexplore.ieee.org/document/6487461/>.
- [6]]Luck2014 LUCK, S. J. *An introduction to the event-related potential technique*. The MIT Press, second edition edition, [2014]. ISBN 978-026-2525-855.
- [7] LUCK, S. J. – KAPPENMAN, E. S. *The Oxford handbook of event-related potential components*. Oxford University Press, 2013 edition, 2013. ISBN 978-019-9328-048.
- [8] MACHIDA, R. – TANAKA, H. Visualization of ERD/ERS on leg Motor Imagery. *International Symposium on Affective Science and Engineering*. 2018, ISASE2018, 0, s. 1–6. ISSN 2433-5428. doi:

- 10.5057/isase.2018-C000022. Dostupné z: https://www.jstage.jst.go.jp/article/isase/ISASE2018/0/ISASE2018_1_12/_article.
- [9] NAKAYASHIKI, K. et al. Modulation of event-related desynchronization during kinematic and kinetic hand movements. *Journal of NeuroEngineering and Rehabilitation*. 2014, 11, 1. ISSN 1743-0003. doi: 10.1186/1743-0003-11-90. Dostupné z: <http://jneuroengrehab.biomedcentral.com/articles/10.1186/1743-0003-11-90>.
- [10] ONO, T. – KIMURA, A. – USHIBA, J. Daily training with realistic visual feedback improves reproducibility of event-related desynchronisation following hand motor imagery. *Clinical Neurophysiology*. 2013, 124, 9, s. 1779–1786. ISSN 13882457. doi: 10.1016/j.clinph.2013.03.006. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1388245713002204>.
- [11] PFURTSCHELLER, G. Graphical display and statistical evaluation of event-related desynchronization (ERD). *Electroencephalography and Clinical Neurophysiology*. 1977, 43, 5, s. 757–760. ISSN 00134694. doi: 10.1016/0013-4694(77)90092-X. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/001346947790092X>.
- [12] PFURTSCHELLER, G. Functional brain imaging based on ERD/ERS. *Vision Research*. 2001, 41, 10-11, s. 1257–1260. ISSN 00426989. doi: 10.1016/S0042-6989(00)00235-2. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0042698900002352>.
- [13] PFURTSCHELLER, G. – SILVA, F. L. Event-related EEG/MEG synchronization and desynchronization. *Clinical Neurophysiology*. 1999, 110, 11, s. 1842–1857. ISSN 13882457. doi: 10.1016/S1388-2457(99)00141-8. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1388245799001418>.
- [14] SADEGHIAN, E. B. – MORADI, M. H. Fractal Dimension for Detection of ERD/ERS Patterns in Asynchronous Brain Computer Interface. *2008 2nd International Conference on Bioinformatics and Biomedical Engineering*. 2008, 2008, 10049365, s. 560–563. doi: 10.1109/ICBBE.2008.136. Dostupné z: <http://ieeexplore.ieee.org/document/4535016/>.
- [15] SEELAND, A. et al. Spatio-temporal Comparison between ERD/ERS and MRCP-based Movement Prediction. *Proceedings of the International Conference on Bio-inspired Systems and Signal Processing*. 2015-1-12, s. 219–226. doi: 10.5220/0005214002190226. Dostupné z: <http://www.scitepress.org/DigitalLibrary/Link.aspx?doi=10.5220/0005214002190226>.

- [16] TOYAMA, J. – ANDO, J. – KITAZAKI, M. Event-related de-synchronization and synchronization (ERD/ERS) of EEG for controlling a brain-computer-interface driving simulator. *Proceedings of the 16th ACM Symposium on Virtual Reality Software and Technology - VRST '09*. 2009, s. 239–. doi: 10.1145/1643928.1643984. Dostupné z: <http://portal.acm.org/citation.cfm?doid=1643928.1643984>.

Přílohy

Příloha A: Uživatelská příručka	46
Příloha B: Obsah CD	48

A Uživatelská příručka

V této kapitole jsou vysvětlen postup spuštění obou aplikací a popsán postup jak lze vykreslit grafy zobrazené v k 8.1.

A.1 Spuštění aplikací

Obě aplikace byly vyvíjeny a testovány ve verzi pythonu 3.6.8 a proto je vhodné, pro zajištění správné funkčnosti, používat aplikace právě v této verzi pythonu. Dále je nutné mít nainstalované potřebné balíky. Pro soubor `erders.py` jsou to balíky "numpy" a "mne". Pro soubor `unn.py` jsou to balíky "numpy", "pandas" a "keras".

Po nainstalování všech těchto věcí stačí otevřít příkazovou řádku v místě umístění aplikace a zadat příkaz "python `erders.py`". Po skončení tohoto programu se vytvoří dva soubory (`train.txt` a `test.txt`). Poté je nutné tyto dva soubory přejmenovat na `train.csv` a `test.csv`. Bohužel se nepodařilo soubory ukládat rovnou v csv formátu, protože když byly ukládány v csv formátu zapisovalo to i nesmyslné čárky a tento problém se nepodařilo odstranit.

Následně je možné spustit klasifikátor příkazem "python `unn.py`". Po skončení klasifikátor vypíše minimální, maximální a průměrnou přesnost (viz obr. A.1).

A.2 Postup vykreslení grafů

Pro zobrazení grafů stačí pouze odkomentovat/zakomentovat nějaké řádky.

Aby program vykreslil vyfiltrované epochy pro ERD je nutné odkomentovat řádek 83 a zakomentovat řádek 81 (pro ERS je třeba odkomentovat řádek 77 a zakomentovat řádek 75). Pro vykreslení vyfiltrovaných a umocněných

```
FINAL RESULT
```

```
acc: 78.94%  
min: 68.75%  
max: 85.42%
```

Obrázek A.1: Výsledky klasifikátoru s 500 neuronu v první skryté vrstvě a 250 neurony ve druhé skryté vrstvě.

epoch ERD je nutné pouze odkomentovat řádek 83 (pro ERS je to řádek 77). Je možné vykreslit graf po vyfiltrování, umocnění a zprůměrování epoch pro ERD odkomentováním řádku 96 (pro ERS je to řádek 112). Výslední ERD lze vykreslit odkomentováním řádku 105 (pro ERS je to řádek 121). Posledním grafem je vyhlazené ERD, který lze vykreslit odkomentováním řádků 107, 108 a 109 (pro ERS jsou to řádky 123, 124 a 125).

B Obsah CD

K práci je přiloženo CD s následující strukturou:

adresář: aplikace/

V této složce se nachází dva zdrojové soubory. První se jmenuje `orders.py` a slouží k vygenerování příznakových vektorů z EEG dat. Druhý se jmenuje `unn.py` a slouží ke klasifikaci vygenerovaných vektorů. Dále se v něm nachází podadresář s názvem EEG, který obsahuje všechna potřebná data ke spuštění souboru `orders.py`.

adresář: dokument/

Tento adresář obsahuje úplný zdrojový text práce a také text práce v elektronické podobě ve formátu pdf. Dále obsahuje podadresář `img`, ve kterém se nachází všechny obrázky nutné k překladu zdrojového textu na pdf dokument.