

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

Diplomová práce

**Detekce pohybu končetin
z EEG signálu při cvičení
na rehabilitačním robotovi.**

ZÁPADOČESKÁ UNIVERZITA V PLZNI

Fakulta aplikovaných věd
Akademický rok: 2020/2021

ZADÁNÍ DIPLOMOVÉ PRÁCE (projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Bc. Pavel MOCHURA**
Osobní číslo: **A19N0072P**
Studijní program: **N3902 Inženýrská informatika**
Studijní obor: **Medicínská informatika**
Téma práce: **Detekce pohybu končetin z EEG signálu při cvičení na rehabilitačním robotovi**
Zadávající katedra: **Katedra informatiky a výpočetní techniky**

Zásady pro vypracování

1. Prostudujte funkci rehabilitačního robota dostupného na KIV.
2. Navrhněte scénář pro měření a detekci pohybu končetin z EEG signálu při cvičení na rehabilitačním robotovi.
3. Naměřte dostatečný počet EEG záznamů (alespoň 5 osob) a vytvořte program pro analýzu dat a navrhněte a implementujte klasifikátor pro detekci pohybu končetin z EEG dat.
4. Ověřte klasifikátor pro detekci pohybu končetin z EEG dat a zhodnoťte dosažené výsledky.

Rozsah diplomové práce: **doporuč. 50 s. původního textu**
Rozsah grafických prací: **dle potřeby**
Forma zpracování diplomové práce: **tištěná**

Seznam doporučené literatury:

dodá vedoucí diplomové práce

Vedoucí diplomové práce: **Ing. Pavel Mautner, Ph.D.**
Katedra informatiky a výpočetní techniky

Datum zadání diplomové práce: **11. září 2020**
Termín odevzdání diplomové práce: **20. května 2021**

L.S.

Doc. Dr. Ing. Vlasta Radová
děkanka

Doc. Ing. Přemysl Brada, MSc., Ph.D.
vedoucí katedry

Prohlášení

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

V Plzni dne 29.03.2021

Bc. Pavel Mochura

Abstract

The EEG signals of the measured subjects contain different patterns depending on what the measured subject was doing. ERD/ERS are examples of such patterns that are tied to hand, finger or foot movements. This paper deals with the detection of motion in EEG signal based on ERD and ERS patterns. Symptom vectors are constructed using either all the values from ERD/ERS or values computed from just these patterns, such as MAV or dispersion. These vectors are classified by a neural network that consists of an input layer, three hidden layers and one output layer, where the first hidden layer contains 400 neurons, the second 200 neurons and the third 100 neurons. A training set consisting of symptom vectors is used to train this neural network and Backpropagation algorithm is used for subsequent rebalancing. This tuned neural network is able to classify the motion in EEG recordings with an average accuracy of 90.05%.

Abstrakt

EEG signály u měřených subjektů obsahují různé vzory podle toho, co měřený subjekt vykonával. ERD/ERS jsou příklady právě takovýchto vzorů, které jsou svázány s pohybem ruky, prstu nebo nohy. Tato diplomová práce se zabývá detekováním pohybu v EEG signálu na základě vzorů ERD a ERS. Příznakové vektory jsou konstruovány buď pomocí všech hodnot z ERD/ERS nebo z hodnot, počítaných právě z těchto vzorů, jako například MAV nebo rozptyl. Tyto vektory jsou klasifikovány neuronovou sítí, která se stává z jedné vstupní vrstvy, třech skrytých vrstev a z jedné výstupní vrstvy, kde první skrytá vrstva obsahuje 400 neuronů, druhá 200 neuronů a třetí 100 neuronů. Pro natrénování této neuronové sítě je použita trénovací množina tvořená příznakovými vektory a pro následné přenastavování vah je použit algoritmus Backpropagation. Takto nastavená neuronová síť je schopna klasifikovat pohyb v EEG záznamech s průměrnou přesností 90,05%.

Poděkování

Na tomto místě bych chtěl poděkovat všem, kteří byli ochotni přijít na měření a poskytnout mi tímto cenná EEG data. 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	10
2.1	Postup měření	10
2.2	Evokované potenciály	12
2.2.1	Zrakové evokované potenciály	12
2.2.2	Sluchové evokované potenciály	13
2.2.3	Somatosenzorické evokované potenciály	14
2.2.4	Motorické evokované potenciály	14
3	Pohyb v EEG	16
3.1	Kognitivní evokované potenciály	16
3.1.1	Přípravný motorický potenciál	17
3.2	Synchronizace a desynchronizace spektrálních vlastností EEG	18
3.2.1	Kvantifikace ERD a ERS v čase	19
3.2.2	Mapování ERD a ERS v prostoru	20
4	Klasifikace pohybu v EEG	23
4.1	Příznakové vektory	23
4.1.1	Fraktální dimenze	23
4.2	Umělé neuronové sítě	24
4.2.1	Vrstvy neuronové sítě	26
4.2.2	Typy umělých neuronových sítí	27
4.2.3	Učení umělých neuronových sítí	29
5	Rehabilitační roboti	31
5.1	Současné používání rehabilitační roboti	33
5.1.1	Pokročilé rehabilitační technologie	34
6	Návrh postupu pro detekci pohybu ruky v EEG záznamech.	37
7	Návrh scénáře pro měření EEG na rehabilitačním robotovi	38
8	Měření EEG	40
8.1	Použitý rehabilitační robot	41
8.2	Použitá technika k měření EEG signálů	42
8.3	Výsledné soubory	43

9	Předzpracování dat	47
9.1	Výpočet ERD a ERS	48
9.2	Výpočet ERD a ERS v alfa a beta pásmech	53
10	Tvorba příznakových vektorů	54
11	Klasifikace pohybu	57
11.1	Modul Keras	57
11.2	Modul Pandas	57
11.3	Neuronová síť	58
11.3.1	Model neuronové sítě	59
12	Testování	60
13	Dosažené výsledky	61
14	Závěr	70
	Přehled zkratk	71
	Literatura	72
A	Uživatelská příručka	76
A.1	Spuštění aplikace	76
A.2	Vykreslení grafů	76
B	Obsah ZIP souboru	77

1 Úvod

Dnešní doba přináší mnoho pokrokových technologií usnadňujících život, a to ve všech oborech lidské činnosti. Pokud jde o odvětví týkající se této diplomové práce, tedy zdravotnictví, lze s trochou nadsázky říci, že dříve vážné až smrtelné nemoci například tetanus, tyfus, apendektomie a podobně, se řadí, především díky zdravotní osvětě a následnému očkování, ale i možnostem dnešní medicíny, k nemocím lehkým a nezávažným, jako třeba k rýmě nebo angíně. Existují však zdravotní stavy a příhody kde zatím řešení není tak snadné a jednoduché a následky jsou mnohem závažnější. Mám na mysli stavy po prodělaných mozkových příhodách, ať už ischemických nebo hemoragických a stavy poúrazové, kde kromě poškození mozku může dojít i k přerušení míchy. Podle rozsahu a vážnosti poškození mozku nebo míchy dochází kromě jiného k částečné nebo úplné paralýze dolních případně i horních končetin, tedy částečné nebo úplné paraplegii, případně kvadruplegii. Klasifikátor, jenž je předmětem této diplomové práce, bude schopen v záznamech EEG detekovat úmysl pohybu s dostatečně dobrou úspěšností klasifikace, může být výše zmíněným pacientům velice ku prospěchu. Dalším předpokládaným krokem je propojit klasifikátor s rehabilitačním robotem, který pak bude reagovat na úmysly postižené osoby provést určitý pohyb, se kterým rehabilitační robot pacientovi pomůže. Konečným výsledkem by mělo být zkvalitnění a usnadnění života těchto lidí, případně i návrat zpět do běžného života.

První část této diplomové práce popisuje teoretické znalosti, které se týkají EEG signálů. Jedná se zejména o všechny různé druhy evokovaných potenciálů nebo jak je možné detekovat pohyb, či představu pohybu za pomoci takzvaného ERD/ERS (Event-related desynchronization/synchronization). V této teoretické části je uvedeno i mnoho způsobů jak je možné vytvořit příznakové vektory z výše uvedeného ERD a ERS, které jsou potřeba pro následnou klasifikaci s využitím neuronových sítí. Dále je zde uveden teoretický obecný popis umělých neuronových sítí a několik učících algoritmů s nimi souvisejících. V poslední řadě tato část zabíhá do problematiky rehabilitačních robotů a ukazuje několik konkrétních příkladů jak z klasických rehabilitačních robotů, tak i z pokročilých rehabilitačních technologií.

Druhá část této diplomové práce popisuje nejprve navržený scénář, následně použitý u měření EEG dat. Dále popisuje výpočet ERD/ERS, ERD pro alfa pásmo, ERS pro nižší beta pásmo, ERD pro beta pásmo a ERS pro vyšší beta pásmo, ze kterých se poté tvoří mnoho různých typů přízna-

kových vektorů. Následně je zde popsána implementace použité neuronové sítě a její následné testování pomocí nastavování různých parametrů a přidávání nebo ubírání skrytých vrstev. V poslední řadě jsou v této části vypsány a okomentovány rozsáhlé dosažené výsledky této diplomové práce.

Zdrojové soubory jak pro zpracování dat tak pro implementaci neuronové sítě jsou psány v programovacím jazyku Python ve verzi 3.8.5. EEG data byla načtena a následně zpracovávána pomocí modulu MNE, který je přímo určený pro zpracování, analýzu a vizualizaci lidských neurofyziologických dat. Umělá neuronová síť je implementována s použitím modulu Keras, který je vyvinutý pro rychlé a velmi účinné modelování umělých neuronových sítí.

2 Elektroencefalografie

Elektroencefalografie, zkráceně EEG, je diagnostická metoda, která se používá k záznamu elektrické aktivity mozku. EEG se řadí mezi neinvazivní metody, protože se snímají změny v polarizaci neuronů pomocí povrchových elektrod Ag/AgCl. EEG se měří pomocí přístroje zvaného elektroencefalograf.

Přístroj se skládá ze snímacích elektrod, které jsou umístěné ve speciální EEG čepici a zesilovače. Speciální EEG čepice osazená snímacími elektrodami dokáže snímat elektrické potenciály, které vznikají synchronizovanou činností obrovského počtu neuronů. Výsledkem celého měření je elektroencefalogram. Elektroencefalogram obsahuje mnoho EEG křivek, jejichž počet je závislý na tom, kolik elektrod bylo při měření použito.

Aktivita mozku se rozděluje do mnoho pásem podle frekvence a amplitudy vln [7]. Základní typy pásem je možné vidět v tabulce 1.


Typ pásma	Rozsah frekvence v Hz	Amplituda v μV	Podmínky přítomnosti
Alfa	8-12	5-100	Zavřené oči a fyzická relaxace
Beta	18-30	2-20	Soustředění, stres, napětí, ...
Gama	30-50	2-10	Extrémně zátěžové situace
Delta	0,5-4,0	20-200	Spánek beze snů
Theta	5-7	5-100	Hluboká relaxace na pokraji spánku
Lambda	Ostré transienty (Hroty)	5-100	Objevuje se v bdělém stavu

Tabulka 2.1: Typy EEG pásem podle rozsahu frekvence a podle velikosti amplitudy

2.1 Postup měření

Nejprve se buď nasadí speciální EEG čepice, která je již osazená elektrodami a nebo se elektrody přímo umísťují na povrch lebky rovnoměrně podle již

definovaných schémat. Jedno z těchto schémat je systém 10-20 (viz obrázek 2.1).



Obrázek 2.1: Na tomto obrázku je podrobně zobrazené rozmístění elektrod podle systému 10-20.

V těchto již definovaných schématech jsou elektrody nejčastěji označovány těmito písmeny[7]:

- T - Temporal
- O - Occipital
- F - Frontal
- P - Parietal
- C - Central
- A - Ear lobe

Ke každému písmenu je ještě přiřazeno liché číslo, pokud se elektroda nachází nad levou mozkovou hemisférou, a nebo sudé číslo, když se elektroda nachází nad pravou mozkovou hemisférou. Ve speciálním případě se místo čísla může použít písmeno *z*, pokud je elektroda přímo mezi oběma hemisférami mozku. Existují dvě možnosti zapojení. Prvním zapojením je unipolární a druhým je bipolární. Pokud je použito bipolární zapojení, tak

se snímá rozdíl potenciálů mezi dvěma elektrodama, které jsou aktivní. V případě použití unipolárního zapojení se vždy snímá napětí mezi elektrodou, která je aktivní a mezi referenční elektrodou. V případě unipolárního zapojení je možné a vhodné ještě rozlišovat směr zapojení a to levo-pravé zapojení a nebo předozadní zapojení. Tyto oba směry je i možné kombinovat.

V poslední řadě je třeba vytvořit správné vodivé prostředí. Tohle prostředí se u neinvazivních povrchových elektrod vytváří za pomoci vodivého gelu.

2.2 Evokované potenciály

Evokované potenciály (EP) jsou v podstatě elektrické odpovědi, které vznikají v nervovém systému a jsou vyvolány nějakými vnějšími podněty. Konkrétně jde o diskrétní změny elektrické aktivity nervového systému (1-10% základní aktivity mozku). Evokované potenciály jsou děleny do mnoha kategorií podle toho, jaký stimul je vyvolává [1]. Mezi tyto kategorie patří například:

- Zrakové evokované potenciály - VEP, Visual Evoked Potentials
- Sluchové evokované potenciály - BAEP, Brainstem Auditory Evoked Potentials
- Somatosenzorické evokované potenciály - SEP, Somatosensory Evoked Potentials
- Motorické evokované potenciály - MEP, Motor Evoked Potentials


Evokované potenciály je také možné dělit podle latencí na krátko-latentní (BAEP), středně-latentní (SEP nebo MEP) a dlouho-latentní (VEP).

Výše popsané potenciály slouží především k zhodnocení funkčního stavu příslušné nervové dráhy (je možné tím odhalit například epilepsii). Dále testují, jaké množství času potřebuje mozek na přijetí a interpretování daného podnětu (například zrakového nebo sluchového). Při běžných podmínkách a za normálních okolností zdravý mozek reaguje s nepatrným zpožděním. Ovšem pokud je nervový přenos nějakým způsobem porušen, celá reakce na podnět trvá mnohem déle (například při roztroušené skleróze).

2.2.1 Zrakové evokované potenciály

Zrakové evokované potenciály vznikají jako odpověď mozku na podráždění zrakových receptorů v sítnici definovaným optickým podnětem. Pro vyvolání zrakových evokovaných potenciálů se využívá buď zábleskový podnět

(aktivuje evokované potenciály hůře než strukturovaný podnět a není až tak diagnosticky významný) nebo strukturovaný podnět. Zábleskový podnět se využívá například u nespolupracujících dětí, protože zde není podmínka, že se vyšetřovaný subjekt musí dívat do středu obrazovky. Strukturovaný podnět je zpravidla šachovnice se změnou černých a bílých čtverců, které se opakují v určité frekvenci a s určitým kontrastem. Dále pak velmi záleží na velikosti čtverců (při jejich zmenšování dochází k poklesu amplitudy a prodloužení latence). Pro vyšetření zrakových evokovaných potenciálů se především využívají elektrody s označením *Cz* a *Oz* [1]. Ukázkový příklad zrakových evokovaných potenciálů je vyobrazen na obrázku 2.2




Obrázek 2.2: Graf Zrakových evokovaných potenciálů. Při vyšetření se zkoumá vlna P100 zobrazená na obrázku.

2.2.2 Sluchové evokované potenciály

Sluchové evokované potenciály vznikají jako odpověď mozku na podráždění sluchového receptoru definovaným akustickým podnětem. Zaznamenává se odpověď, která vzniká po podráždění sluchového receptoru. Frekvence této stimulace je zpravidla 10 Hz. Při stimulaci zvukovým podnětem je třeba určit sluchový práh, podle něhož se určí výsledná intenzita stimulace jako sluchový práh + 20dB až 30dB. Jako stimul slouží krátký nefiltrovaný zvukový podnět, který je přiveden na membránu pacientových sluchátek. Stimuluje se každé ucho zvlášť a nejčastěji se používají elektrody s označením *Cz* [1].

Sluchové evokované potenciály se používají pro vyšetření sluchu. Největší výhodou BAEP ve srovnání s ostatními diagnostickými metodami pro stanovení poškození sluchu spočívá právě v její větší objektivnosti. Příklad zvukových evokovaných potenciálů je zobrazen na obrázku 2.3.



Obrázek 2.3: Graf sluchových evokovaných potenciálů

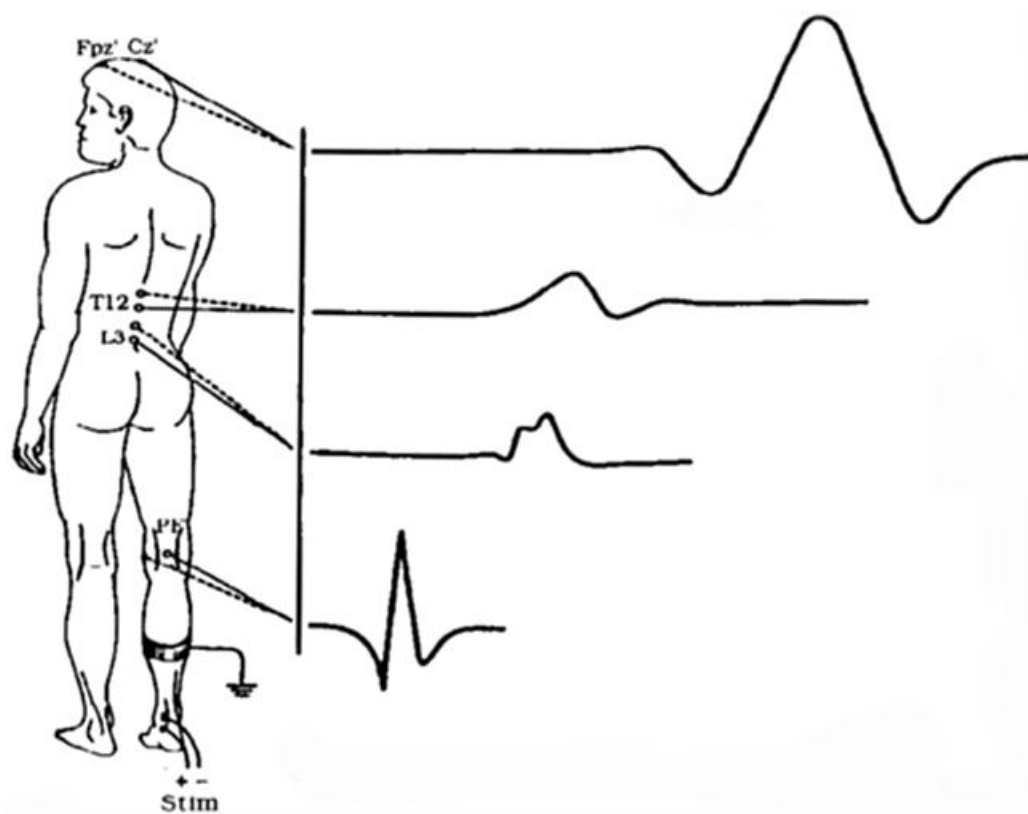
2.2.3 Somatosenzorické evokované potenciály

Somatosenzorické evokované potenciály jsou odpověď mozku na podráždění aferentních somatosenzorických vláken periferního nervu definovaným elektrickým podnětem. Intenzita stimulace je 3-4x nad senzitivní práh. Senzitivní práh je práh vnímání podráždění elektrickým proudem na kůži [1].

Obecně metoda SEP vyhodnocuje zdravotní stav periferních nervů a míchy. SEP také testuje, jak mícha nebo mozek přenáší informace o smyslových podnětech. Díky této metodě je možné přesně lokalizovat, ve kterém místě došlo k blokaci signálu a jestli je problém v přenosové soustavě (periferní nervy) nebo v interpretačním centru (mozek nebo mícha). Nejčastěji se využívají elektrody s označením Cz a Fz. Příklad použití SEP je zobrazen na obrázku 2.4.

2.2.4 Motorické evokované potenciály

Motorické evokované potenciály vznikají jako odpověď svalu na definované magnetické nebo elektrické podráždění mozkové kůry. Stimulací motorických buněk v mozkové kůře se vzruch šíří kortikospinální dráhou k alfa-motoneuronu předních rohů míšních a odtud k příslušnému svalu. Pro dolní končetiny se používá elektroda Cz. Pro horní končetiny se používají elektrody C3 a C4, podle toho jestli se jedná o pravou nebo levou ruku [1].



Obrázek 2.4: Zobrazuje použití somatosenzorických potenciálů v praxi, včetně použitých elektrod a místa stimulace.

3 Pohyb v EEG

Pro detekování pohybu (například pohyb ruky nebo nohy) se v EEG dají použít tzv kognitivní evokované potenciály (Event-related potentials - ERP)[9, 10], ke kterých je možné zařadit například Bereitschaftspotential (BP - přípravný motorický potenciál) [3, 12, 18]. Druhou možností pro detekování pohybu v EEG signálu je využití synchronizace a desynchronizace spektrálních vlastností EEG (tzv. ERD/ERS), které se nachází v naměřených EEG datech. S využitím ERD/ERS je teoreticky možné poznat, zda subjekt myslel na pohyb nějaké své končetiny a přitom samotný pohyb ve skutečnosti nevykonal.

3.1 Kognitivní evokované potenciály

Kognitivní evokované potenciály jsou v současnosti považovány za odraz aktivity komplexních neuronálních sítí, které odpovídají za detekci nových podnětů a za rozlišovací chování osob. Tyto pomalé mozkové potenciály jsou vázány na kognitivní aktivitu, která může být vědomá i nevědomá [1].


V průběhu měření kognitivních evokovaných potenciálů si subjekt pohodlně sedne nebo lehne. Dále musí být přesně instruován vyšetřujícím (tyto instrukce je nejlepší vysvětlit ještě před měřením), jaký konkrétní pohyb, kterou končetinou, a kdy přesně v průběhu měření tento pohyb má vykonávat.

Snímací elektrody, které jsou umístěné ve speciální EEG čepici, jsou rozmístěné pomocí standardního systému 10-20, který je popsán v kapitole 2.1. Počet těchto elektrod je limitován počtem kanálů, které jsou k dispozici na registrujícím přístroji. Pro měření kognitivních evokovaných potenciálů se nejčastěji používají kanály s označením Cz, C3, C4, Fz, Pz, P3, P4. Nepoužívají se vždycky všechny kanály, ale záleží především na tom, jakou částí těla daný subjekt hýbe. Například pokud subjekt hýbe levou rukou, používají se elektrody umístěné především nad pravou mozkovou hemisférou a pokud hýbe pravou rukou, tak se naopak používají elektrody, které jsou umístěné nad levou mozkovou hemisférou. Posledním krokem je umístění referenční a zemnicí elektrody. Referenční elektrodou může být jakákoli elektroda umístěná na speciální EEG čepici nebo je možné ji umístit na kořen nosu. Zemnicí elektrodu je nejvhodnější umístit na ušní lalůček. Pokud chceme zaznamenat i elektromyografickou odpověď (EMG), umístíme další elektrody na břicho snímaného svalu a zemnicí elektrodu je vhodné

umístit na končetinu, s níž se při měření vykonává pohyb, a to v místě, kde vzdálenost od elektrody ke kosti je nejmenší.

3.1.1 Přípravný motorický potenciál

Readiness Potential, Bereitschaftspotential nebo též přípravný motorický potenciál byl popsán v polovině 60. let 20. století Kornhuberem a Deeckem jako tzv. Bereitschaftspotential. Přípravný motorický potenciál se začíná objevovat přibližně asi jednu sekundu před tím, než si vyšetřovaný subjekt uvědomí, že chce vykonat nějaký pohyb (viz obrázek 3.1). Tento fakt je také hlavní důvod, proč BP souvisí s vědomými, ale také i s nevědomými aktivitami. BP může být a je ovlivňován řadou fyzikálních i psychologických parametrů. Též nepředchází jen pohybu, který je člověkem vykonán, ale také pohybu, jenž nebyl subjektem proveden, a tudíž tyto potenciály velmi úzce souvisí s kognitivní aktivitou, která je vázána na pohyb [1].



Obrázek 3.1: Idealizované zobrazení přípravného motorického potenciálu ve vztahu k pohybu. BP byl rozdělen na část 1 a část 2 v čase přibližně -400 ms, což odpovídá ranému BP a pozdnímu BP.

Bereitschaftspotential je získáván zprůměrováním EEG signálu, který je spouštěn opakovaným pohybem. Tento pohyb je většinou jednoduchý. Jedná se například o pohyb prstu, nohy nebo ruky. BP je reprezentován křivkou skládající se z několika částí, které se v mnoha literaturách liší názvem, protože je má v podstatě každý autor jinak pojmenované. Nejčastěji se však první část křivky označuje jako BP1. Tato část začíná přibližně 1500 - 800 milisekund a končí zhruba 500 milisekund před začátkem pohybu. Druhá část křivky navazuje na první část křivky. Tedy začíná přibližně 500 milisekund a končí asi 50 milisekund před začátkem pohybu. Tato druhá část se nazývá nejčastěji BP2 nebo také NS (negative shift). Do BP2 může být těsně před začátkem pohybu vepsána krátká pozitivita (premovement potential - PMP). Tato pozitivita jsou nekonzistentní. Fyziologický význam jednotlivých

komponentů zatím nebyl nijak objasněn.

3.2 Synchronizace a desynchronizace spektrálních vlastností EEG


Od Bergera 1930 je známo, že některé určité události mohou zablokovat nebo desynchronizovat probíhající činnost alfa. Tyto změny jsou sice časově uzamčené pro událost, ovšem ale nejsou fázově uzamčené, a proto nemohou být extrahovány nějakou jednoduchou lineární metodou, ale mohou být poměrně slušně detekovány frekvenční analýzou nebo také Fourierovou transformací. Tento fakt ukazuje, že události související s jevy frekvenční specifikace změn probíhající EEG aktivity, mohou obecně spočívat buď v poklesu nebo zvyšování výkonu v daných kmitočtových pásmech. To může být považováno za pokles nebo zvýšení synchronizace základních populací neuronů.

Rozlišujeme dva případy. Prvním případem je takzvané ERD nebo také Event-related desynchronization a druhý případ se nazývá Event-related synchronization, neboli ERS. Jevy ERD a ERS se vyskytují nejen u EEG záznamů, ale také u MEG záznamů. Na rozdíl od tradičních kognitivních evokovaných potenciálů, které je možné považovat za řadu přechodných postsynaptických reakcí vyvolené specifickým stimulem, tak ERD a ERS jevy lze považovat za změny v jednom nebo také více parametřích, které řídí oscilace v síti neuronů [6, 11, 14, 16] (viz obr. 3.2).

Zde je velice vhodné uvést, jaké jsou obecné vlastnosti těchto kmitů. Druhy hlavních faktorů určujících vlastnosti oscilací EEG:

1. Dynamika synaptických procesů a vlastnosti vnitřních membrán neuronů.
2. Rozsah a pevnost propojení mezi síťovými prvky, které jsou nejčastěji vytvořené zpětnovazebními smyčkami. Lze rozlišovat mnoho různých typů zpětnovazebních smyček. Buď zahrnují kortiko-kortikální nebo thalamo-kortikální na dlouhé nebo na krátké vzdálenosti.
3. Modulační účinky z obecných nebo lokálních neurotransmiterních systémů.

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



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

3.2.1 Kvantifikace ERD a ERS v čase

Jeden ze základních a hlavních rysů měření ERD a ERS je ten, že výkon EEG/MEG v rámci identifikovaných kmitočtových pásem je zobrazen relativně k spektrální výkonové hustotě stejných EEG/MEG zaznamenaných během stimulačního nebo také klidového období několik sekund před nastávajícím stimulem (V našem případě se jedná o pohyb jedné ruky). Pokud jde o rytmy alfa pásma, tak změny související s událostí v probíhajícím EEG/MEG vyžadují čas na vývoj a obnovu. Vzhledem k tomuto faktu, interval mezi dvěma po sobě jdoucími událostmi by měl trvat nejméně několik sekund.

Existuje mnoho metod pro výpočet časového průběhu ERD/ERS. Klasická metoda (Pro jednoduchost ji označme jako metodu 1) zahrnuje následující kroky:

1. Vyjmutí epoch související s událostí a následná pásmová filtrace dat v epochách.
2. Druhé umocnění hodnot všech vzorků v epoše.
3. Zprůměrování všech souvisejících epoch.
4. Finální vyhlazení zprůměrovaných vzorků.

Tento postup je sice účinný, ale má za následek změnu časového průběhu hodnot výkonu pásma. Při použití této klasické metody (metody 1) může dojít k tomu, že EP, který vzniká před vykonáním pohybu, může výrazně ovlivnit pokles výkonu ERD. Tento problém je možné odstranit využitím následující metody (opět pro jednoduchost jí označíme za metodu 2):

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

Rozdíl mezi metodou 1 a metodou 2 popsal Kalcher a Pfurtcheller v roce 1995. Bylo zjištěno, že pokud se jedná o složky s nižší frekvencí (dolní alfa a theta pásma) může, v důsledku ERP, fázově blokový nárůst výkonu maskovat nepoužívaný pokles ERD při použití klasické metody (metody 1) pro výpočet časového průběhu ERD.

Procentuální hodnoty ERD/ERS je možné získat následujícími rovnicemi:

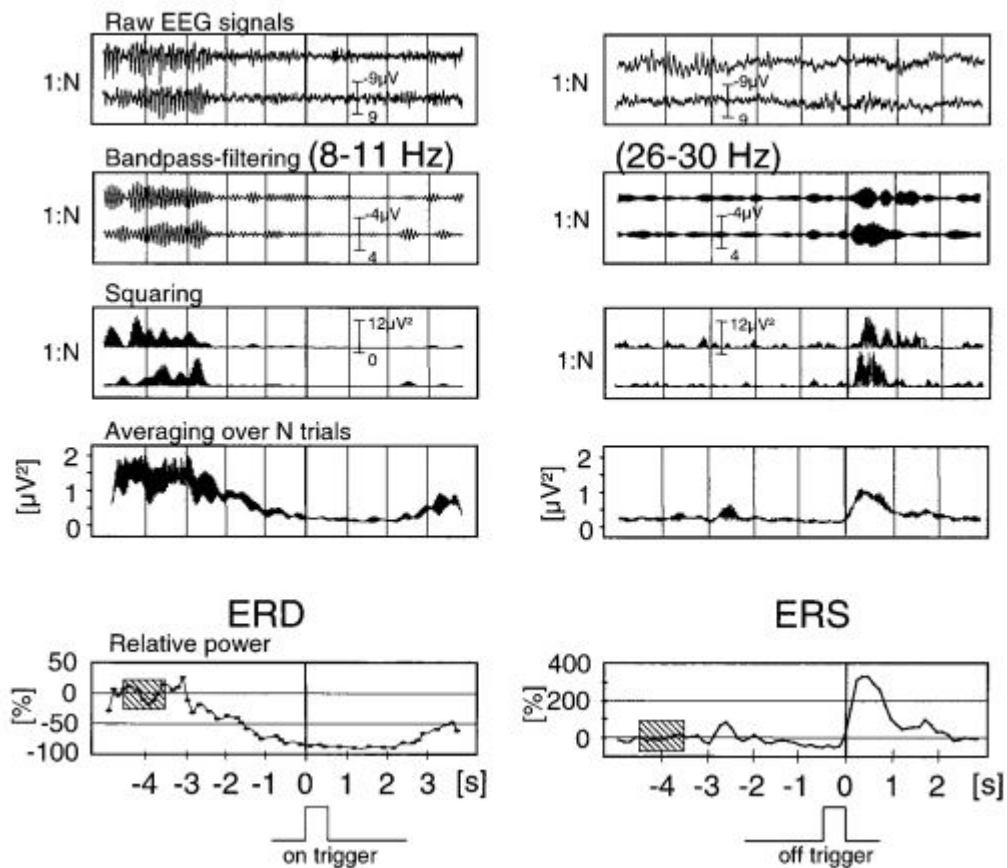
$$ERD = \frac{R - A}{R} \times 100 \quad (3.1)$$

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

kde písmeno A označuje výkon v rámci sledovaného kmitočtového pásma v čase po události. Hodnota v čase před událostí je dána písmenem R. Výše uvedené výrazy definují ERD a ERS jako procentní podíl snížení nebo zvýšení výkonu. Kompletní zobrazení výpočtu ERD i ERS je možné vidět na obrázku 3.3, kde je zobrazen jeden příklad dominantního ERD v alfa pásmu na levé straně a jeden příklad s dominantním ERS v beta pásmu na pravé straně [16].


3.2.2 Mapování ERD a ERS v prostoru

Obvykle jsou vícekanálové EEG signály zaznamenávány proti standardní referenční elektrodě. Z toho vyplývá, že jsou data závislá na referenční elektrodě. Existují různé metody pro přepočítání EEG dat závislých na referencích, které jsou podrobně popsány Lopesem da Silvou et al. (1993), Pfurtcheller (1992). Ve srovnání s referenčními mapami obecně vykazují mapy bez referencí více ohniskových vzorů a jsou zvláště doporučovány, když jsou analyzována data odpovídající pohybovému úkolu.



Obrázek 3.3: Kompletní princip zpracování ERD (zobrazeno v levé části) a ERS (zobrazeno v pravé části). Snížení výkonu pásma signalizuje ERD a zvýšení výkonu pásma ERS.

Také jsou k dispozici různé metody pro prostorové mapování ERD a ERS, jako je například výpočet povrchového napětí, kortikálního zobrazování a zobrazování s distribuovaným zdrojem. Příklad ERD map vypočítaných pomocí několika metod před pohybem pravé ruky je možné pozorovat na obrázku 3.4[4, 15]. Jak je možné vidět, s těmito různými metodami existují pouze okrajové rozdíly v místě zaměření ERD [16, 19].



Obrázek 3.4: Distribuce ERD, která byla vypočítána před pohybem pravé ruky. Mapy na obrázku jsou zobrazeny shora. (a) Spline surface Laplacian, která je vypočítaná na realistickém modelu hlavy. (b) Spline surface Laplacian zobrazená na realistickém modleu hlavy a vypočítaná na modelu sférické hlavy. (c) Výsledky lineárního odhadu založené na realistickém modelu hlavy.

4 Klasifikace pohybu v EEG

Získaný EEG signál měřeného subjektu je možné rozdělit do mnoha epoch, ze kterých lze následně dle výše uvedených postupů vypočítat procentní podíl snížení nebo zvýšení výkonu (ERD/ERS). Výsledné ERD a ERS je možné si představit jako pole čísel, které obsahuje přesně tolik položek jako má daná epocha milisekund, kde každé číslo v poli představuje sílu signálu v určité milisekundě. Z těchto dat je třeba nějakým způsobem vytvořit příznakové vektory, které bude možné použít ke klasifikaci. V poslední řadě je velice důležité zvolit vhodný klasifikátor pro nejlepší možnou úspěšnost klasifikace pohybu v EEG.

4.1 Příznakové vektory

Aby bylo možné klasifikovat pohyb z EEG signálu, je nejprve potřeba nějakým způsobem vytvořit příznakové vektory, které budou vstupní hodnotou do příslušného klasifikátoru. Jednou a pravděpodobně nejjednodušší možností je vytvořit příznakový vektor jako pole, jehož délka bude stejná jako součet velikostí ERD a ERS. Následně je možné do toho prázdného příznakového vektoru vložit ERD a bezprostředně za něj pak ERS. Tímto způsobem vzniknou jednoduché, ale neuvěřitelné dlouhé příznakové vektory (cca 5 000 prvků).

Druhou možností jak je možné vytvořit příznakové vektory je nakombinovat nějaké jiné prvky vypočítané z již vypočítaných ERD a ERS. Mezi tyto jiné prvky může patřit například průměrná absolutní hodnota, rozptyl, relativní výkon beta pásma k alfa pásmu, relativní výkon beta pásma k celkovému výkonu nebo například singulární hodnoty EEG bez artefaktů [2]. Do těchto prvků je možné zahrnout i fraktální dimenze [17].

4.1.1 Fraktální dimenze

Fraktál je jakýsi složitý tvar a Mandelbrot tvrdí, že existuje přirozená dimenze, do níž každý takový fraktál pasuje nejvíce. Fraktální dimenze D je reprezentována individuálním číslem (to je velice často ve tvaru zlomku), které lze použít jako základní kvantifikaci i těch nejsložitějších tvarů. Pro rovinné křivky, které postupují "dopředu" monotónně, jsou fraktální rozměry v rozmezí mezi $D = 1,0$ (pro přímé čáry) až do $D = 1,5$ (pro některé vysoce špičaté vlny). Skutečné tvary vln se nikdy nemohou dostatečně tak stočit,

aby vyplnily celou rovinu. Proto tyto křivky nikdy nemohou mít fraktální rozměry blížíící se rozměrnosti roviny, konkrétně $D = 2,0$. Odhad fraktální dimenze D rovinné křivky je obecně [5]:

$$D = \frac{\log(L)}{\log(d)}, \quad (4.1)$$

kde L je celková délka křivky a d je průměr (rovinný rozsah) křivky. Pro křivky, které jsou definovány uspořádanými sadami dvojic bodů (x, y) je celková délka L jednoduše součtem vzdáleností mezi po sobě jdoucími body, tj.:

$$L = \text{sum}(\text{dist}(i, i + 1)), \quad (4.2)$$

kde $\text{dist}(a, b)$ znamená vzdálenost mezi body $a = (x, y)$ a $b = (u, v)$. Vlny postupující vpřed monotónně mají přirozené výchozí body. Rovinný rozsah nebo průměr tvaru vlny lze tedy považovat za největší vzdálenost mezi počátečním bodem (bod p) a jakýmkoli jiným bodem (bod i) definujícím křivku, tj.:

$$d = \text{max}(\text{dist}(p, i)) \quad (4.3)$$

Jedna praktická konvence pro diskretizaci prostoru a pro normalizaci fraktálových rozměrů definuje standardní jednotku jako velikost nejmenší konvoluce nebo "zakroucení". V podstatě se měřítkem rozumí nejmenší vnímatelná jednotka změny tvaru (nejmenší vnímatelná derivace). Další obecná konvence definuje standardní jednotku jako průměrný krok nebo konvoluci tvaru. U křivek je tento průměrný krok a , průměrná vzdálenost mezi po sobě následujícími body [5]. Pomocí a se vzorec pro fraktální dimenzi D modifikuje na:

$$D = \frac{\log(\frac{L}{a})}{\log(\frac{d}{a})} = \frac{\log(n)}{\log(n) + \log(\frac{d}{L})} \quad (4.4)$$


kde $n = L/a$ je počet kroků ve křivce.

4.2 Umělé neuronové sítě


Umělé neuronové sítě (Nebo také ANN - Artificial neural network) jsou v dnešní době jedním z hlavních nástrojů používaných ve strojovém učení ke klasifikaci. Jak je zřejmé z názvu, jsou to systémy, které jsou inspirované lidským mozkem a neurony, které se v něm nachází. Hlavním cílem těchto systémů je replikace způsobu, jakým se lidé učí.

Obecně se Umělé neuronové sítě skládají ze tří druhů vrstev. Jedná se o vrstvu vstupní, skrytou a výstupní. Tyto vrstvy se stávají z jednoho nebo více neuronů (model jednoho neuronu je možné vidět na obrázku 4.1), které napodobují biologické neurony lidského mozku. Z obrázku 4.1 je patrné, že do každého neuronu vede N vstupů a každý z těchto vstupů obsahuje svůj vlastní váhu. Váha je nějaké reálné číslo, kterým se násobí vstup. Vstupy do neuronu je možné chápat jako výstupy z neuronů v předchozí vrstvě. Neuron dále obsahuje prahovou hodnotu, někdy také nazývanou jako potenciál neuronu. Pokud je potenciál neuronu překonán, neuron je "nabuzen" a vysílá signál na výstup ve formě aktivační funkce. Jako aktivační funkce se nejčastěji používá sigmoida nebo hyperbolická tangenta. Veškeré vstupy a výstupy jsou reprezentované synapsemi, nebo také vazbami. Jak již bylo řečeno, každá vazba obsahuje svůj vlastní váhu. Tyto vazby spojují všechny vrstvy v umělé neuronové síti tak, že z neuronů v předchozí vrstvě vedou vazby (synapse) do neuronů v následující vrstvě. Tímto způsobem je propojena celá neuronová síť.

Pomocí výše zmíněných vah je zajištěna schopnost učení neuronové sítě. Z toho faktu je zřejmé, že "učení neuronové sítě" je ve své podstatě jen změna hodnot, které jsou uloženy ve váhách. Obrázek 4.2 ukazuje příklad struktury celé neuronové sítě.



Obrázek 4.1: Model umělého neuronu, jehož struktura je navržena podle matematického modelu nazývaného perceptron. Na tomto modelu je možné vidět více vstupů (každý s jinou váhou), prahovou hodnotu kterou obsahuje neuron a přechodovou funkci, ze které vzejde výstupní hodnota.



Obrázek 4.2: Model umělé neuronové sítě. Tento model obsahuje jednu vstupní vrstvu, která obsahuje pouze tři neurony. Dále obsahuje dvě skryté vrstvy, kde v každé skryté vrstvě jsou čtyři neurony. Nakonec obsahuje i jednu skrytou vrstvu, která ovšem zobrazuje pouze jeden jediný neuron, z čehož vyplývá, že tato neuronová síť dokáže vzorky klasifikovat pouze do dvou tříd. Jsou zde také zobrazeny všechny vazby mezi všemi vrstvami.

4.2.1 Vrstvy neuronové sítě

Jak již bylo řečeno, neuronové sítě se skládají ze tří druhů vrstev. Mezi tyto vrstvy patří vstupní, výstupní vrstva a v podstatě neomezený počet skrytých vrstev.

Vstupní vrstva je tvořena jen z příznakových vektorů. Z toho vyplývá, že počet neuronů ve vstupní vrstvě se rovná počtu prvků v příznakovém vektoru.

Výstupní vrstva je tvořena třídami, do kterých se snaží umělá neuronová síť daný příznakový vektor zařadit. Na základě toho faktu je zřejmé, že nám ve výstupní vrstvě bude stačit pouze jeden jediný neuron. Pokud tento výstupní neuron bude "svítit", tedy hodnota tohoto neuronu překročí prahovou hodnotu, tak to bude znamenat, že daný příznakový vektor na vstupu bude pravděpodobně vytvořen z epochy, která obsahuje pohyb. Pokud ovšem tuto hodnotu nepřekročí, je velice pravděpodobné, že zde pohyb vykonán nebyl.

Asi nejsložitější vrstvy, které tvoří jádro umělých neuronových sítí, jsou

vrstvy skryté. Tyto vrstvy mohou obsahovat libovolný počet neuronů v závislosti na tom, kolik jich je třeba pro nejlépejší klasifikaci. Též může neuronová síť obsahovat klidně 2 skryté vrstvy nebo také 100 skrytých vrstev. Tyto vrstvy slouží pro "transformaci" hodnot, které do těchto vrstev vstupují za pomoci vah synapsí a aktivačních funkcí.

4.2.2 Typy umělých neuronových sítí

Rozlišují se dva hlavní a základní typy neuronových sítí, podle typu propojení (vazeb) a to dopředné nebo rekurentní. U dopředných sítí jsou vždy výstupy neuronů jedné vrstvy připojené jako vstupy následující vrstvy. U rekurentních sítí je možnost propojit výstup neuronu na svůj vlastní vstup, popřípadě na vstup jiného neuronu ve své vlastní vrstvě. Tím pádem výstupy jedné vrstvy mohou být ovlivněny svým vlastním výstupem. Tento přenos je občas nazýván jako zpětnovazební přenos. Rekurentní sítě mají hlavní využití v oblasti, kde záleží na pořadí vstupů, tzn. zajímá nás časová složka dat. Do takové oblasti patří například klasifikace, rozpoznávání nebo predikce v obrazových (video, nikoli obrázky) či hlasových datech.

Sítě je také možné dělit na husté nebo řídké neuronové sítě, podle "hustoty" propojení mezi jednotlivými vrstvami. Pokud je síť označena za hustou, znamená to, že všechny výstupy ze všech neuronů v každé vrstvě jsou propojeny se vstupy všech neuronů v následující vrstvě. U řídkých vrstev výše zmíněné pravidlo neplatí. To znamená, že u řídkých sítí mohou být propojeny mezi sebou pouze některé neurony.


Dopředné neuronové síť

Feed-Forward síť neboli též dopředné neuronové síť jsou nejběžnější typ neuronových sítí. Tyto sítě jsou konstruovány tak, že výstupy z jedné vrstvy jsou napojené na vstupy vrstvy následující, a tudíž na rozdíl od rekurentních sítí neobsahují žádné zpětné smyčky (V jejich modelu neexistuje žádný cyklus). Z toho důvodu tak není žádný problém využít algoritmus back-propagation pro její natrénování. Topologie dopředné sítě je možné vidět na obrázku 4.2.

Rekurentní neuronové síť

Jak již bylo výše zmíněno, rekurentní neuronové sítě obsahují smyčky, kdy výstupy nějaké vrstvy jsou zároveň vstupy té samé vrstvy. V nejjednodušším případě je výstup jedné vrstvy i závislý na výstupu následující vrstvy $i+1$.

Výhoda těchto sítí je v tom, že umožňují použití u mnohem více komplexnějších úloh než obyčejné dopředné sítě, avšak ne vždy se hodí pro jakýkoli problém. Nevýhodou rekurentních neuronových sítí je zejména výpočetní čas, potřebný na prohledání celého prostoru řešení, který je mnohem větší než u dopředné sítě. Tyto sítě se často využívají u architektur obsahujících roboty nebo umělé agenty, jelikož rekurentní spojení neuronů umožňují využití paměti při rozhodovacím procesu. Při rozhodování, jestli použít rekurentní neuronovou síť, je velice vhodné položit si otázku, zda je jejich použití nezbytné a vhodné pro daný problém, protože rekurentní sítě jsou velice specifické a jak již bylo zmíněno výše, nehodí se pro jakýkoli problém. V poslední řadě je také nutné vhodně zvolit reprezentaci vstupních dat (příznakové vektory). Příklad rekurentní neuronové sítě je zobrazen na obrázku 4.3.




Obrázek 4.3: Rekurentní neuronová síť - je možné si všimnout vazeb, které vycházejí ze skryté vrstvy a míří do stejné skryté vrstvy. Díky těmto vazbám tak výstup skryté vrstvy závisí na výstupu té samé skryté vrstvy. Z toho důvodu není možné použít klasický učicí algoritmus Back-propagation.

Kvůli tomu, že rekurentní neuronové sítě obsahují zpětné smyčky, není možné pro učení použít klasický Back-propagation algoritmus, ale je třeba tento algoritmus trošku modifikovat, aby zohledňoval i zpětné smyčky. Tato modifikovaná metoda se nazývá Back-propagation through time (BPTT).

Konvoluční síť

Konvoluční neuronové sítě jsou zvláštním druhem dopředných neuronových sítí, které obsahují nejen klasické neuronové vrstvy, ale také vrstvy složené z konvolučních filtrů. Tyto sítě slouží převážně pro rozpoznání nebo detekci objektů nacházejících se v obraze, kdy jejich konvoluční vrstvy dokáží extrahovat ze vstupního obrazu určité vzory, se kterými je tato síť schopná dále pracovat. Příklad takovéto sítě je možné vidět na obrázku 4.4



Obrázek 4.4: Příklad konvoluční neuronové sítě. Jsou zde zobrazené tzv. pooling vrstvy, které slouží k postupnému snižování dimenze vstupních dat z neuronů předchozích vrstev do jediného neuronu vrstvy následující. Pooling vrstvy jsou klíčovým prvkem konvolučních sítí.

4.2.3 Učení umělých neuronových sítí

Umělé neuronové sítě jsou schopné se učit změnou vah v jednotlivých synapsích jak již bylo zmíněno v kapitole *Umělé neuronové sítě*. Tento trénink probíhá pomocí tzv. trénovací množiny dat. Existuje mnoho metod, pomocí kterých je možné neuronové sítě učit. Učení neuronových sítí lze rozdělit na dva základní typy. Jedná se o učení s učitelem a o učení bez učitele.

Učení bez učitele

Pokud se neuronové sítě učí bez učitele, tak jsou váhy vazeb nastavené tak, aby výstup umělé neuronové sítě byl co nejlepší a hlavně konzistentní, tzn. aby síť poskytovala naprosto stejnou odezvu při totožných nebo také velmi podobných vstupních příznakových vektorech.

Učení s učitelem

Učení s učitelem je nejčastější způsob učení umělých neuronových sítí. Při tomto učení se neuronová síť učí porovnáváním aktuálního výstupu s požadovaným výstupem a snaží se nastavit váhy tak, aby s k tomuto požadovanému výstupem pokud možno co nejvíce přiblížil. Učitelem je v těchto metodách právě požadovaný výstup. Mezi metody učení s učitelem patří například algoritmus Back-propagation.

Back-propagation je nejčastěji používaná metoda učení a proto je v některých knihovnách často nastavená, jako výchozí metoda učení. Tato metoda je jedna z možností pro jemné vyladění vah v umělé neuronové síti na základě chybovosti, která je získaná v předchozí iteraci (někdy označované jako předchozí období). Váhy synapsí se aktualizují za pomoci klesání gradientu. Nejprve se s ohledem na nastavené váhy v neuronové síti vypočítá gradient chybové funkce. Celý výpočet probíhá zpětně sítí (proto Back-propagation) a lze jej vyjádřit následující rovnicí:

$$*W_x = W_x - \alpha \frac{\delta Error}{\delta W_x} \quad (4.5)$$

kde $*W_x$ je výsledná nová váha. W_x je váha z předchozí iterace. α značí míru učení. Na konec nejstěžejnější část celého vzorce je výraz pro parciální derivaci $\frac{\delta Error}{\delta W_x}$ chybové funkce *Error* s ohledem na jakoukoli váhu W v celé umělé neuronové síti. Tato parciální derivace nám říká, jak rychle se cena změní, když změníme váhy. Z tohoto důvodu je Back-propagation velice rychlý algoritmus pro učení. Back-propagation nám ve skutečnosti dává detailní pohled na to, jak změna váhy mění kompletně chování umělé neuronové sítě.

Například pro aktualizaci váhy W_3 vezmeme váhu W_3 a odečteme parciální derivaci chybové funkce s ohledem na W_3 . Následně násobíme derivaci chybové funkce vybraným číslem α (míra učení), abychom se ujistili, že výsledná nová váha minimalizuje chybovou funkci.

5 Rehabilitační roboti

Rehabilitační robot by se dal jednoduše definovat jako jakýkoli automaticky ovládaný stroj, který je přímo určený ke zlepšení pohybu osob s nějakým pohybovým omezením[8].

Rehabilitační roboty lze rozdělit do dvou hlavních základních typů. Prvním typem je tzv. asistenční robot, který nahrazuje pohyby ztracených končetin. Příkladem může být Manus ARM (asistenční robotický manipulátor), což je robotická ruka na invalidním vozíku, která je ovládána pomocí bradového spínače nebo jiného vstupního zařízení (s použitím této ruky je pacient schopen si například podat batoh jen s použitím brady). Tento proces se nazývá telemanipulace a je podobný tomu, jako když astronaut ovládá robotickou ruku kosmické lodi z její kabiny. Mezi takovéto roboty patří i například invalidní vozík s pohonem.

Druhým typem rehabilitačních robotů je tzv. terapeutický robot, kterému se někdy též říká rehabilitátor. Výzkum v oblasti neurověd ukázal, že mozek a mícha si i po úrazu zachovávají pozoruhodnou schopnost adaptace, a to pomocí nacvičených pohybů. Terapeutické roboty jsou stroje nebo nástroje pro rehabilitační terapeutky, které umožňují pacientům provádět nácvik pohybů za pomoci robota. První takto používaný robot MIT - Manus pomáhal pacientům po mrtvici dosáhnout přes desku stolu, pokud nebyli schopni tento úkol provést sami. U pacientů, kterým robot poskytoval dodatečnou terapii, se zlepšila rychlost obnovy pohybů ruky. Dalším terapeutickým robotem je například "Lokomat"(viz obrázek 5.1) , který podporuje váhu člověka a pohybuje nohama v chůzi po pohyblivém běžeckém pásu s cílem přeškolit člověka v chůzi tak, aby byl schopný chodit i po poranění míchy nebo mrtvici.

Všeobecně největšími problémy všech rehabilitačních robotů je omezení funkčnosti a vysoké náklady, které omezují dostupnost rehabilitačních robotů. Navíc teleoperace robotické paže, která má zvednout láhev s vodou a přinést ji k ústům je časově náročná a vyžaduje drahého robota. Aby tento problém byl překonán, tak se momentálně pracuje na zabudování větší inteligence do robotických paží, které jsou vestavěné v invalidních vozících. Další důležitou oblastí pokroku v robotice je, aby byli roboti schopni reagovat na hlasové příkazy, rozpoznávali předměty a hbitě s nimi manipulovali. Tento pokrok v neurovědách může významně posunout vývoj rehabilitačních robotů tím, že umožní implantovat počítačové čipy přímo do mozku, takže stačí, aby uživatel "myslel"na příkaz a robot jej provede. Již je vědecky



Obrázek 5.1: Terapeutický robot nazývaný Lokomat a nějaký pacient, který se pomocí chůze po pohyblivém běžeckém pásu snaží přeškolit v chůzi.

prokázáno, že opice je schopna se naučit pohybovat robotickou rukou právě tímto způsobem pomocí počítačového čipu (pouhým myšlením).

Jedním z hlavních omezujících faktorů při vývoji rehabilitačních robotů je to, že vědci nevědí, co přesně se musí stát, aby se nervový systém přizpůsobil a překonal tělesné postižení. Tvrdá práce pacienta je důležitá, ale co by měl dělat robot? Výzkumníci vyvíjejí rehabilitační roboty, kteří pomáhají při pohybu, brání pohybu, když je nekoordinovaný, nebo dokonce dělají pohyby ještě nekoordinovanější ve snaze oklamat nervový systém, aby se přizpůsobil. Pokroku bylo dosaženo ve vývoji robotických exoskeletů, což jsou lehká nositelná zařízení, která pomáhají při pohybu končetin. Další typy rehabilitačních robotů by mohly hrát roli při pomoci nervovému systému regenerovat vhodná nervová spojení po léčbě kmenovými buňkami a dalších lékařských zákrocích.

5.1 Současně používaní rehabilitační roboti


Za hlavního představitele rehabilitačních robotů je považována švýcarská firma Hocoma, která sehrála průkopnickou roli v robotické rehabilitaci. Ovšem v současné době její postavení na trhu postupně slábne. Hlavním produktem této firmy je rehabilitační robot známý jako Armeo Power (viz obrázek 5.2), ke kterému lze jako doplněk použít přístroj Manovo Power, který umožní nácvik sevření ruky (viz obrázek 5.3).



Obrázek 5.2: Terapeutický robot nazývaný ArmeoPower, který slouží převážně k rehabilitaci horních končetin.

Společnost Hocoma vyrábí i variantu známou jako Armeo Spring, která ale ovšem není aktivně motoricky poháněna, a tudíž jde jen o výborně promyšlený pasivní cvičební prostředek s odlehčením paže od gravitace. Z toho důvodu se jistě jedná o skvělé rehabilitační zařízení, ovšem ne robotické zařízení. Armeo Spring slouží převážně pro rehabilitaci paretické nebo plegické horní končetiny.

Nácvik a obnova chůze se u těžce paraplegicky postižených pacientů řeší již podle výše zmíněného přístroje nazývaného Lokomat, který je též produktem firmy Hocoma (viz obrázek 5.1). Lokomat je velice propracované zařízení, které fixuje pacienta ve vzpřímené poloze a pomocí řady motorů dokáže simulovat chůzi pacienta. Kvůli této složitosti a propracovanosti se



Obrázek 5.3: Doplnkový přístroj k rehabilitačnímu robotu Armeo Power. Pomocí tohoto doplňku je možné trénovat/rehabilitovat sevření horní končetiny.

cena tohoto robota pohybuje přibližně okolo 12 milionů Kč. Velmi důležitou součástí tohoto robota je motivační zpětná vazba, kdy rehabilitující pacient na monitoru umístěném před ním sleduje simulaci své vlastní chůze. Za pomoci této zpětnovazební informace se pacient snaží svoji chůzi řídit. Z toho je samozřejmé, že se stále jen jedná o vizuální informaci, kde nikdy nevíme, zda je tato vizuální informace pacientovým mozkiem zpracována tak dobře, aby mozková kůra produkovala signály, které generují chůzi a směřují eferentním směrem (eferentní směr je takový směr, který vede směrem od mozku). Tento nesoulad je v současné koncepci rehabilitační robotiky nejslabší stránkou. Jediným způsobem, kterým lze tuto slabou stránku překonat, je zavedení vyšší úrovně řízení robota pomocí signálů snímanými a vyhodnocovanými přímo z pacientova mozku. Jen pomocí tohoto způsobu je možné v plné míře uplatnit plasticitu centrálního nervového systému a tím může dojít k opravdu efektivnímu spojení signálů postupujících po eferentních i aferentních (směřujícím směrem k mozku) nervových drahách.

5.1.1 Pokročilé rehabilitační technologie

Z pohledu na současný stav je nezbytné zajít ještě o kousek dál do oblasti současných pokročilých rehabilitačních technologií. Tento zavedený termín *pokročilé rehabilitační technologie* (Advanced Rehabilitation Technology neboli ART) je odvozen z International Industry Society in Advanced Rehabilitation Technology. Jelikož obecně přijímanou definici ART nelze dohledat,

nabízí se srovnání s konvenční fyzikální terapií. Pro ART jsou tedy charakteristické následující body [13]:

1. Nestačí primitivní reflexní reakce. Snaží se o vyvolání vyšších odpovědí.
2. Nejčastěji je kladen veliký důraz na vlastní aktivitu pacienta. U běžné fyzikální terapie, která je založená na předávání fyzikální energie pacientovi, je právě tento pacient většinou pasivní.
3. Pokročilé rehabilitační technologie se snaží využívat zpětnou vazbu pomocí různých senzorů (například pro moment síly nebo polohu) s kombinací dnes již celkem rozšířené virtuální reality.
4. Kvůli náročnějšímu technickému i softwarovému zpracování jsou tyto přístroje výrazně sofistikovanější a samozřejmě i dražší.
5. Pokud se jedná o robotickou terapii, tak přístroj obvykle vykonává mechanickou práci ulehčující či nahrazující pohyb pacienta či práci terapeuta. Případně tyto přístroje jsou schopné klást řízený odpor proti pohybu pacienta.

Jedním z těchto složitějších přístrojů je například zařízení s názvem Gait Trainer vyráběný americkou společností Biodex (viz obrázek 5.4). Tento přístroj realizuje metodu BWSTT nebo také Body Weight Support and Treadmill Training, při které je pacient nejen vertikalizován, ale také zavěšen nebo podepřen a následně nějakým způsobem donucen k reedukaci chůze. Nejčastěji toto donucení probíhá s použitím pohyblivého chodníku.

Dalším z kategorie velmi úspěšných rehabilitačních robotů je například zařízení zvané HapticMaster VR (viz obrázek 5.5) vyrobené firmou Motek. Tento přístroj je možné využívat jako prostředek spojení pohybu paže s virtuální realitou, popřípadě slouží i k nácviku pohybu paže s pevným závěsem předloktí nebo s aktivním uchycením prsty ruky. K roboticky asistované rehabilitaci horní končetiny využívá tento přístroj poměrně jednoduchého závěsu v oblasti zápěstí postižené ruky na výškově nastavitelné a otočné vertikální tyči. HapticMaster VR je rehabilitační robot určený k rehabilitaci horní končetiny, nikoliv však ruky, nebo prstů.



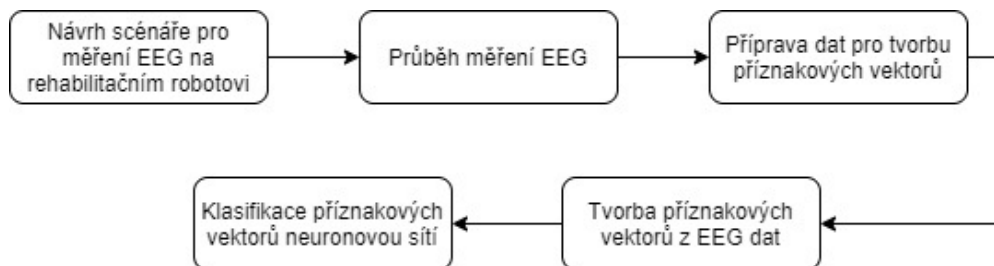
Obrázek 5.4: Příklad přístroje Gait Trainer od americké společnosti Biodex využívající metodu Body Weight Support and Treadmill Training



Obrázek 5.5: Zařízení HapticMaster VR využívající závěsné zařízení a virtuální realitu.

6 Návrh postupu pro detekci pohybu ruky v EEG záznamech.

Abychom mohli klasifikovat pohyb pomocí ERD a ERS v EEG záznamech, tak ze všeho nejdříve je třeba získat nějaká vhodná EEG data. Ovšem abychom mohli získat potřebná data, musíme nejprve vytvořit vhodný scénář, který bude možné použít pro měření EEG dat s použitím rehabilitačního robota. Po vytvoření vhodného scénáře je možné přejít k samotnému měření a tedy získávání EEG záznamů. Z důvodu klasifikace pomocí neuronových sítí je třeba naměřit co nejvíce dat z co možná nejvíce lidí, abychom měli dostatečně velikou klasifikační a trénovací množinu dat. Po naměření dostatečného počtu lidí je třeba získané EEG záznamy upravit příslušnými metodami na ERD/ERS, ze kterých je poté nutné nějakým vhodným způsobem vytvořit příznakové vektory, aby je neuronová síť mohla zpracovat a následně klasifikovat. Samotná klasifikace, jak již bylo výše zmíněno, tedy bude probíhat pomocí jednoduché neuronové sítě, která bude obsahovat maximálně dvě skryté vrstvy. Celý navržený postup je možné detailně vidět na obrázku 6.1.



Obrázek 6.1: Diagram ilustrující navržený postup pro detekci pohybu s rehabilitačním robotem v EEG záznamech. Prvním krokem je návrh scénáře pro měření EEG s rehabilitačním robotem. Následuje průběh samotného měření a následná příprava dat pro tvorbu příznakových vektorů. Dále tvorba příznakových vektorů a posledním krokem je klasifikace pohybu za pomoci neuronové sítě.


7 Návrh scénáře pro měření EEG na rehabilitačním robotovi

Pro naměření kvalitních dat, je třeba vhodně zvolit scénář (viz obrázek 7.1), aby v naměřených datech byla přítomnost ERD/ERS. Při měření proto subjekt sedí na pohodlné polohovací židli a buď levou nebo pravou horní končetinou se drží koncového ramene rehabilitačního robota. Samotný průběh měření sestává z dvou fází (klidová a pohybová fáze), které na sebe bezprostředně navazují. Obě fáze se opakují do té doby, dokud neskončí měření trvající od 10 do 15 minut. Pro signalizaci přechodu mezi těmito fázemi je nad obrazovkou umístěná červená LED. Pokud tato červená dioda svítí, tak se měřená osoba nachází v klidové fázi. Opačně, pokud červená dioda nesvítí, znamená to, že se subjekt nachází v pohybové fázi měření. Jednotlivé fáze tedy jsou:

1. Klidová fáze - V této části je rameno robota nehybné a stejně tak nevykonává žádný pohyb ani měřená osoba. Klidová fáze trvá přesně 10 sekund. Pokud se tato doba ukáže jako přehnaně dlouhá, nebo naopak velmi krátká, je možné její délku při dalším měření jednoduše upravit použitím displeje na rehabilitačním robotovi. Abychom mohli jednoduše v naměřených datech detekovat klidovou fázi, tak jsou v této části měření generovány dvě synchronizační značky s označením S1 a S2:
 - (a) Značka S1 značí začátek klidové fáze.
 - (b) Značka S2 je generována přesně uprostřed klidové fáze, tedy 5 sekund po značce S1.

Značka S2 je využita pro výpočet klidového ERD a ERS, které se bude počítat 3,5 sekundy před a 0,5 sekundy po značce S2. Značka S1 není ve finální podobě této práce nijak využita, protože kdyby se počítalo klidové ERD nebo ERS z této značky, tak by do výsledného klidového ERD/ERS pravděpodobně zasahovalo jak ERD, tak ERS z předchozího pohybu. Tento jev by narušil celou výslednou klasifikaci.

2. Pohybová fáze - Jak již z názvu této fáze vyplývá, tak měřená osoba v pohybové části se snaží pohybovat koncovým ramenem rehabilitačního robota po předem definované trajektorii, která je zobrazena na



Obrázek 7.1: Diagram ilustrující postup scénářem pro měření EEG s naznačeným generováním synchronizačních značek.

monitoru umístěném na rehabilitačním robotovi. V našem případě tato předdefinovaná trajektorie má podobu kruhu. Pohybová část měření trvá 20 sekund. V této fázi jsou opět generovány dvě synchronizační značky, ovšem nyní s označením S4 a S5:

- (a) Značka S5 označuje první pohyb po klidové fázi
- (b) Značka S4 značí veškeré ostatní pohyby v pohybové fázi kromě prvního pohybu označeného výše zmíněnou značkou S5

Aby tyto značky mohly být generovány, tak měřený subjekt musí na koncové rameno robota vyvinout takovou sílu, aby překročila předem nastavený práh a tím byl tento pohyb robotem klasifikován jako pohyb. Jelikož značka S5 následuje víceméně ihned po klidové fázi, tak lokalizace ERD popřípadě ERS v dané epoše by měla být v podstatě jednoduchá. Na rozdíl v epochách vybraných pomocí značky S4 nemusí být detekce ERD či ERS, kvůli možnému negativnímu ovlivnění kontinuálním pohybem robotického ramene, tak snadná jako v případě značek S5. Také u značek S4 může být veliký problém v tom, že vykonávaný pohyb je souvislý a nepředchází mu, žádná klidová část. Z těchto důvodů jsou pro klasifikátor použity pouze značky S5. Značky S4 byly použity v rané fázi této práce, bohužel ale zde přítomnost ERD/ERS byla mizivá a kvůli tomu se s těmito značkami dále nepracovalo. Aby nedocházelo k překryvu jednotlivých segmentů ERD/ERS, tak po každé vygenerované značce S4 nebo S5 následuje tzv. mrtvá zóna, ve které nedochází ke generování dalších značek typu S4. Tato mrtvá zóna je nastavena na 3 sekundy po vygenerování značky a je možné ji opět prodloužit, či zkrátit pomocí displeje robota.

8 Měření EEG

Kvůli pandemickým opatřením, která trvala většinu akademického roku, bylo celkově naměřeno pouze 14 lidí. Z těchto čtrnácti lidí bylo 9 žen ve věkovém rozmezí od 19 do 23 let a jejich průměrný věk byl 19,6 let. Zbýlých 5 otestovaných lidí byli muži ve věku mezi 19 a 22 lety, kde jejich průměrný věk byl 20,8 let.

Abychom dosáhli nejvyšší možné kvality v naměřených datech, byla u každého měření přítomna zdravotní sestřička, proškolená v měření EEG signálů. Před přípravou každého měření bylo měřenému subjektu detailně popsáno jak bude celé vyšetření probíhat a několikrát vysvětleno, co přesně má subjekt vykonávat za pohyby.

Po vysvětlení celého průběhu měření byl dán každému subjektu dotazník, kde musel vyplnit několik základních údajů a vyjádřit svůj souhlas s tímto měřením. Poté, co subjekt vyjádřil svůj souhlas, začala příprava na měření. Měřená osoba se posadila na židli zády ke zdravotní sestřičce, která správně upevnila na hlavu subjektu speciální EEG čepici, která odpovídá systému rozmístění elektrod 10-20 a je osazena elektrodami typu Ag/AgCl (viz kapitola 8.2). Následovalo připevnění 2 elektrod na ruku, kterou subjekt vykonával pohyb, a jedné zemní elektrody umístěné pár centimetrů pod loket, protože v této oblasti je nejmenší vzdálenost od povrchu kůže k loketní kosti. Byla umístěna pouze jedna referenční elektroda a to na ušní lalůček. Poslední elektrodou, která byla umístěna na tělo subjektu, byla další zemní elektroda umístěná na kořen nosu. Finálním krokem této přípravy bylo vmáčknutí speciálního vodivého gelu pod elektrody umístěné v EEG čepici.

Následně byl subjekt přesunut k rehabilitačnímu robotovi (viz kapitola 8.1), kde všechny elektrody byly zapojeny k zesilovači V-Amp (viz kapitola 8.2). Poté byla provedena krátká kontrola odporů všech elektrod a pokud nějaká elektroda měla větší odpor než bylo požadováno¹, tak tento odpor byl redukován pomocí přidání dalšího vodivého gelu pod danou elektrodu. Po vyladění odporů bylo subjektu ještě jednou vysvětleno, co přesně má vykonávat za pohyb a následně si pohyb na nečisto vyzkoušel. Následovalo už jen samotné měření EEG signálů podle scénáře popsáno v kapitole 7.

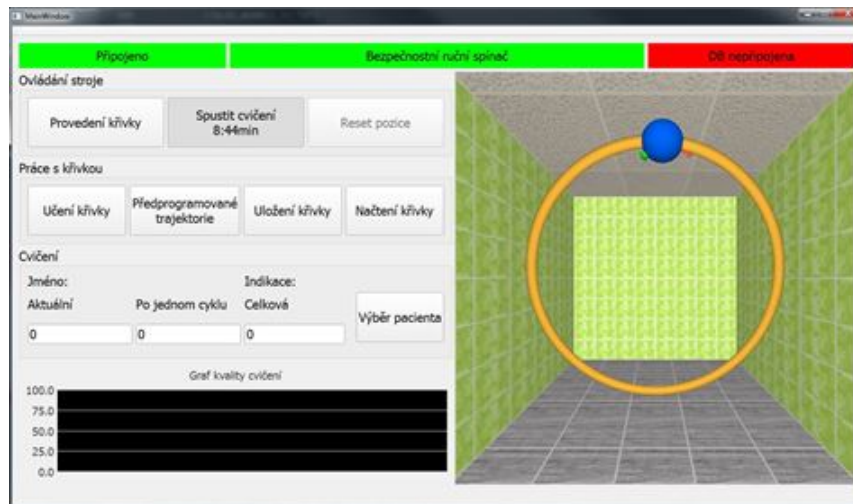
Bohužel v některých případech, pro nás z neznámých důvodů, se robot vypnul dříve než bylo plánováno. V takovýchto případech bylo jednoduše měření zahájeno znovu. Měření bylo zahájeno znovu i v případě, pokud se nám zdálo, že v datech je příliš veliký šum nebo že subjekt nezabíral

¹Na všech elektrodách byl vyžadován odpor maximálně $5K\Omega$

dostatečně velkou silou a tím nepřekročil nastavený práh pro zaznamenání markeru (viz kapitola 7).

8.1 Použitý rehabilitační robot

Při měření EEG signálů byl použit rehabilitační robot (viz obrázek 8.2), který umožňuje víceméně volný pohyb jedné horní končetiny po předem definované křivce (viz obrázek 8.1) zobrazené na obrazovce, která je umístěná v horní části robota na nastavitelném rameni s dosahem okolo celého stroje. Při měření EEG dat použitých v této diplomové práci byla křivka ve tvaru kruhu, ale je možné tutéž křivku nastavit na libovolný tvar. Součástí stroje je také koncové pohyblivé rameno, kterým se snaží subjekt hýbat po výše uvedené křivce.



Obrázek 8.1: Obrazovka umístěná na rehabilitačním robotovi ukazující křivku, po které se má subjekt pohybovat, aktuální umístění na křivce, požadovaný pohyb označený červenou šipkou a aktuální pohyb označený zelenou šipkou. Na tomto obrázku je nastavena křivka ve tvaru kruhu, ale je možné nastavit libovolný tvar této křivky.

K ovládání celého robota slouží na pravém boku umístěný ovládací panel, který se skládá z několika částí. Tyto části jsou vyznačené a popsány na obrázku 8.3, kde jsou jednotlivé části označeny také čísly.



Obrázek 8.2: Rehabilitační robot použitý při měření.

8.2 Použitá technika k měření EEG signálů

Kromě rehabilitačního robota popsaného v kapitole 8.1, byla použita speciální EEG čepice a zesilovač V-Amp.

Speciální EEG čepice je možné vidět na obrázku 8.5. EEG čepice, které byly použity při měření EEG, jsou vybaveny elektrodami typu Ag/AgCl tak, aby odpovídaly systému rozmístění elektrod 10-20. Elektroda s označením Ag/AgCl je typ referenční elektrody, která se běžně používá právě při elektrochemických měření (např. EEG). Dříve se používaly spíše elektrody z kalomelu, ovšem dnes z ekologických důvodů byly nahrazeny výše zmíněnými elektrodami. Mezinárodní systém 10-20 je mezinárodně uznávaná metoda pro popis a použití umístění elektrod na hlavě člověka v rámci EEG

vyšetření, polysomnografické studie spánku nebo dobrovolného laboratorního výzkumu. Čísla 10 a 20 poukazují na skutečnost, že přesné vzdálenosti mezi sousedními elektrodami jsou buď 10% nebo 20% celkové vzdálenosti lebky zepředu dozadu nebo zprava doleva. Například měření se provádí přes horní část hlavy, od nosu k inionu². Většina ostatních běžných měření začíná u jednoho ušního boltce a končí u druhého ušního boltce, obvykle přes temeno hlavy.

Byl použit zesilovač V-Amp od firmy Brain Products (viz obrázek 8.4, který má následující vlastnosti:

- Možnost připojit až 16 kanálů + referenční a zemnicí elektrodu.
- 2 pomocné bipolární kanály.
- Disponuje 8+1 bitovým spouštěcím portem.
- Fyzická vzorkovací frekvence je 2 kHz.

Je možné zapnout tzv. Fast mode, který je pouze pro 4 kanály, ale zvedne se tím fyzická vzorkovací frekvence na 20 kHz.

- Obsahuje 3,5 palcový LCD displej.

Pro zaznamenávání EEG dat byl použit software BrainVision Recorder od firmy Brain Products, což je multifunkční nahrávací program, navržený tak aby poskytoval mimořádně všestrannou a snadno použitelnou platformu pro nastavování a provádění nahrávání. Tento software je kompatibilní se všemi svými zesilovači, takže je vhodné jej použít i v našem případě, jelikož byl použit zesilovač V-Amp také od firmy Brain Products.

8.3 Výsledné soubory

Jak již bylo výše zmíněno, k zaznamenávání EEG dat byl použit software BrainVision Recorder. Tento program generuje po každém jednom měření 3 soubory. Jedná se o soubory s příponami *.vmrk, *.vhdr a *.eeg. Soubor s příponou *.vmrk obsahuje kompletní seznam všech markrů (značek) a časů, kdy byla daná značka pořízena. Seznam námi použitých značek je popsán v kapitole 7. Dalším souborem je soubor s příponou *.vhdr. Tyto soubory v sobě uchovávají kompletní strukturu naměřených dat a nějaké další informace z měření. Mezi tyto informace patří například názvy souborů, kde jsou uloženy značky a EEG data, datový formát EEG dat (v našem případě

²Bod umístěný na týlu hlavy


se jedná o binární formát), počet připojených kanálů, vzorkovací frekvence (naše data mají vzorkovací frekvenci 500 Hz) a nebo jména všech použitých kanálů. Také obsahuje informaci jaký software byl použit pro nahrání EEG dat. V našem případě se tedy vždy jedná o BrainVision Recorder Professional ve verzi 1.23.0003. Posledním souborem je soubor s příponou *.eeg a zde je již celkem z názvu jasné, že tento soubor uchovává samotný záznam EEG dat (v našem případě se tedy jedná o binární soubor). Z tohoto faktu je jasné, že tento soubor bude největším z těchto tří souborů. Pro představu, v našem případě soubory *.vmrk mají velikost přibližně 6,8 kB, *.vhdr mají velikost okolo 3,5 kB a soubor s eeg daty *.eeg mají velikost okolo 52 MB.

Samotný název byl poté volen velice systematicky a skládá se z pěti částí. První část názvu je pouze jediné písmeno a může to být buď písmeno *z* a nebo písmeno *m*. Tyto dvě písmena značí, zda testovaný subjekt je žena či muž. Druhou částí názvů souborů jsou dvě číslice, znázorňující věk testovaného subjektu. Dalšími dvěma znaky jsou iniciály měřeného subjektu, aby bylo možné jej popřípadě dohledat ve vyplněných dotaznících. Předposlední částí názvu je buď dvojice znaků lh (left hand) znázorňující fakt, že člověk hýbal při měření levou rukou nebo rh (right hand) pro pravou ruku. Pátou a zároveň poslední částí je číslo, určující z kolikátého měření jsou data pořízena. Tato poslední hodnota nabývá většinou hodnoty 1, protože každý subjekt byl většinou měřen právě jednou na každou ruku, ale jak již bylo výše popsáno, tak v některých případech se měření zapínalo vícekrát, a proto některé soubory jsou na konci označeny číslem 2.

Příkladem takového kompletního názvu může být soubor pojmenován jako z23nlrh1.eeg. Tento soubor tedy svým jménem říká, že se jedná o EEG data naměřená z prvního měření od 23 let staré ženy s iniciály NL, která hýbala při měření pravou rukou.



Obrázek 8.3: Na tomto obrázku jsou zobrazeny všechny části ovládacího panelu k použitému rehabilitačnímu robotovi. Jednotlivé oblasti jsou popsány čísly: 1) Hlavní dotyková obrazovka, pomocí které se nastavují různé parametry při měření. 2) Tlačítko "Chyba"- Pokud svítí, tak je stroj zastaven a vyžaduje pozornost. 3) Tlačítko "Připraven"- indukuje připravenost k zapnutí cvičení. 4) Klíček sloužící pro odblokování bezpečnostního režimu. 5) Tlačítko "Total STOP"slouží k nouzovému vypnutí robota. 6) Tlačítko "Kvítace"se využívá pro potvrzení chybového stavu. 7) Kontrolka automatického režimu. 8) Tlačítko "Vypínání"slouží pro přepnutí do režimu automat. 9) USB konektor pro nabíjení tabletu. 10) RJ45 konektor sloužící pouze pro servisní účely. 11) Držák tabletu.



Obrázek 8.4: Zesilovač V-Amp od firmy Brain Products, ve kterém je právě zapojeno 16 elektrod



Obrázek 8.5: Speciální EEG čepice osazená elektrodami Ag/AgCl podle systému 10-20

9 Předzpracování dat

Všechna data jsou zpracovávána v programovacím jazyce Python s využitím modulu MNE. MNE je open-source balíček pro Python, který je přímo určen ke zkoumání, zpracování, analýze a vizualizace neurofyziologických dat, jako je například EEG, MEG, EKG a mnoho dalších. Tento modul byl zvolen převážně tedy proto, že pracujeme s EEG daty a to nám modul MNE může výrazně usnadnit. Ovšem i když se zdá MNE na první pohled jako výborná volba, tak i tento modul má své nevýhody. Asi největší nevýhodou je velmi rozsáhlá dokumentace, která je velice nepřehledná, poněvadž po aktualizaci tohoto balíku ne vždy všechny změny uvedou i do dokumentace.

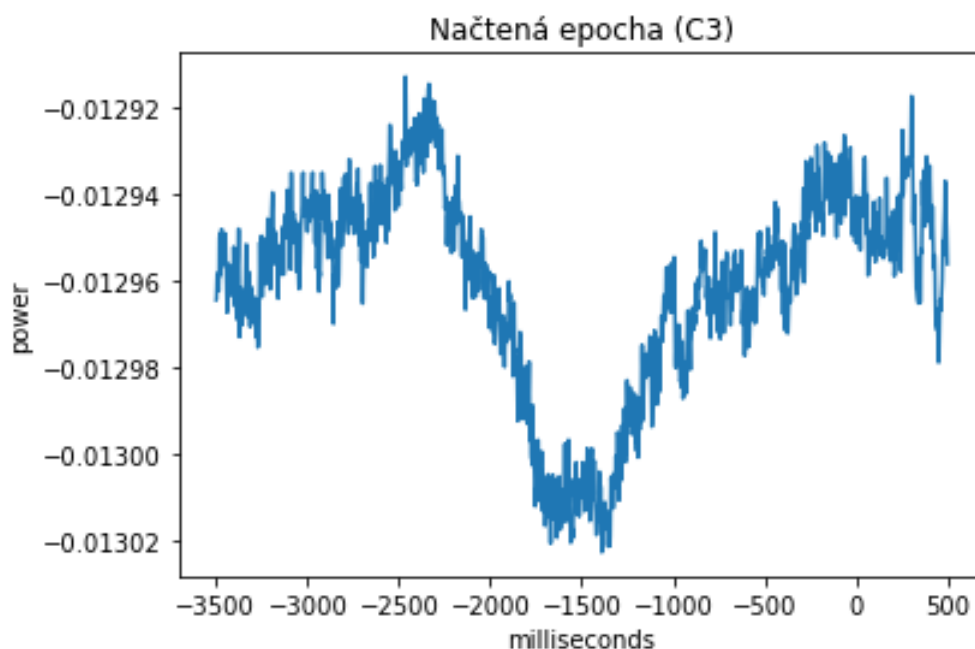
Ze všeho nejdříve, než jsou data zpracovávána je třeba udělat pár úkonů. První takovou záležitostí je data správně načíst, aby s nimi bylo možné pracovat. Jelikož nenačítáme pouze jediný soubor, tak si vytvoříme pole s názvem eeg do kterého tyto data budeme načítat. K načtení dat do pole slouží následující příkazy.

```
eeg.append(mne.io.read_raw_brainvision("cesta k souboru"))
eeg[i].load_data()
```

Prvním výše uvedeným příkazem jednoduše načteme data do pole. Po tomto načtení přichází na řadu druhý příkaz, který naimportuje načtená data do MNE abychom s nimi mohli dále pracovat.

Další důležitou věcí je zjistit, jakou rukou pacient zrovna hýbal. Tento fakt je velice vhodné znát, protože lidský mozek je konstruován tak, že pravá mozková hemisféra ovládá levou ruku a levá mozková hemisféra ovládá pravou ruku. Z toho důvodu potřebujeme vědět, jakou rukou subjekt při měření hýbal, abychom mohli vybrat elektrodu, ze které budeme používat data k dalšímu zpracování. Budeme vždy volit mezi elektrodou s označením C3 (umístěná nad levou hemisférou) pro pohyb pravé ruky nebo C4 (umístěná nad pravou hemisférou) pro pohyb levé ruky. To, zda pacient hýbal levou či pravou rukou, lze jednoduše, díky šikovnému pojmenování souborů, poznat právě z názvu, konkrétně ze šestého a sedmého znaku načítaného souboru.

Příklad jedné načtené epochy, která pochází pouze z elektrody C3, je možné vidět na obrázku 9.1



Obrázek 9.1: Tento graf vykresluje příklad jediné epochy načtené z elektrody C3, když subjekt hýbal pravou rukou.

9.1 Výpočet ERD a ERS

Nyní, když máme načtená data a víme jaká elektroda (C3/C3) nás zajímá, tak je možné přistoupit k samotnému výpočtu ERD. Prvním krokem k výpočtu ERD je vyfiltrovat načtená data podle frekvence. Jelikož se ERD nachází převážně ve frekvencích od 8 Hz do 12 Hz, tak chceme filtrovat načtená data právě v této frekvenci. K takovéto filtraci nám slouží příkaz:

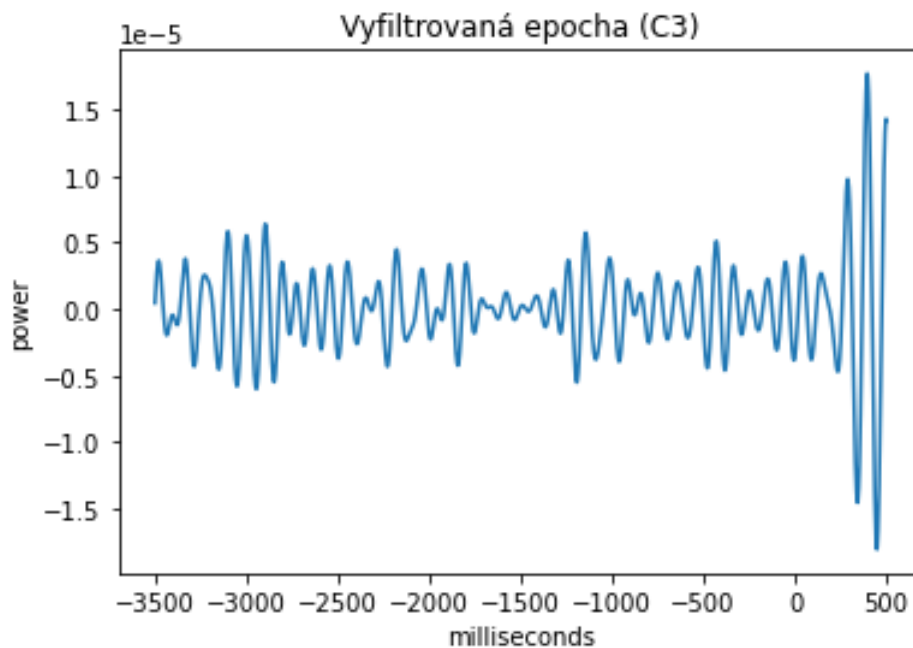
```
eeg[i].filter(8,12,fir_design="firwin")
```

Tento příkaz pustí na načtená data filtr s konečnou impulsní odezvou, který dokáže vyfiltrovat načtená data v námi požadované frekvenci, tedy od 8 Hz do 12 Hz. Příklad takového vyfiltrovaného signálu je možné vidět na obrázku 9.2.

Po vyfiltrování EEG signálu podle frekvence je třeba všechny hodnoty umocnit na druhou. K aplikování nějaké funkce (například druhé mocniny) na EEG data je vhodné použít následující funkci:

```
eeg[i].apply_function(square)
```

Bohužel tato funkce není schopná používat jakékoli funkce, které obsahují více než jeden parametr. Z toho důvodu byla vytvořena jednoduchá



Obrázek 9.2: Vyfiltrovaná epocha z obrázku 9.1, ve frekvenci pro výpočet ERD, tj. 8 Hz - 12 Hz.

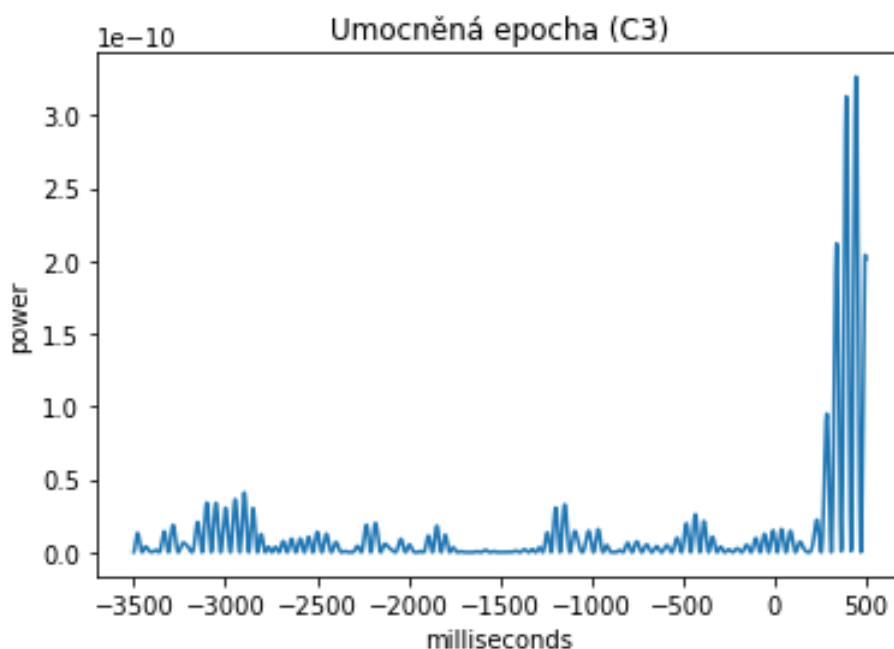
funkce `square`, která jako jediný vstupní parametr má EEG data. Funkce `apply_function(square)` aplikuje na všechna vyfiltrovaná data funkci `square`, do které jako vstupní parametr pošle právě zpracovávaná EEG data. Funkce `square` je definována takto:

```
def square(eeg):
    eeg = np.power(eeg, 2)
    return eeg
```

Jak je možné vidět, tak výše zmíněná funkce `square` opravdu jen umocní na druhou data, která do ní přijdou jako vstupní parametr a umocněná data samozřejmě vrátí. K tomuto umocnění je využita metoda `power` z balíku NumPy. Příklad jedné umocněné epochy je možné vidět na obrázku 9.3.

Po umocnění všech dat je vhodné vybrat z dat epochy, které nás zajímají. Jelikož se předpokládá, že epoch z každého souboru je více, vytvoříme si opět pole `epochsERD` do kterého vložíme všechny epochy. Následné vybrání všech epoch probíhá následujícím příkazem:

```
epochsERD.append(mne.Epochs(eeg[i], events[0], event_id[ei],
tmin, tmax,baseline=None, preload=True, picks=chan))
```




Obrázek 9.3: Umocněná epocha na druhou z obrázku 9.2.

Výše uvedený příkaz pro vybrání epoch má mnoho parametrů. Prvním parametrem jsou vstupní EEG data. Dalšími parametry jsou `events` a `event_id`, čímž řekneme jaká značka nás zajímá. V našem případě je to buď marker označený číslem 5 nebo číslem 2 (viz kapitola 7). Dalšími extrémně důležitými parametry jsou `tmin` a `tmax`. Tyto parametry určují jak velké budou výsledné epochy takovým způsobem, že `tmin` určuje dobu před značkou a `tmax` po značce. Například, pokud se zvolí `tmin = 2` a `tmax = 3`, tak epocha bude vybrána 2 vteřiny před značkou až 3 vteřiny po značce. V našem případě je nastaveno `tmin = -3,5` a `tmax = 0,5`. Jsou zvoleny takové hodnoty, protože ERD a ERS se vyskytuje až 2,5 vteřiny před událostí a až 0,5 vteřiny po události. Před událostí ovšem bereme o jednu vteřinu více, kvůli finálnímu výpočtu ERD a ERS viz rovnice 9.2. Dalším zásadním parametrem je parametr `baseline`, který je nutné nastavit na `none`. Kdybychom nastavili jinou baselinu nebo tento parametr dokonce smazali, tak by se nastavila defaultní baseline a naše umocněná data by se přizpůsobila tomuto parametru a mohla by poté obsahovat i záporné hodnoty, takže by celé umocnění bylo k ničemu. Posledním důležitým parametrem je parametr `picks`, který jen říká, z jakých elektrod data chceme brát. V našem případě tedy tento parametr bude vždy nastaven na hodnotu buď `C3` nebo `C4`.

Poté co nalezneme všechny potřebné epochy, je na čase je všechny zprůměrovat. Zprůměrování všech epoch se řeší tímto jednoduchým příkazem:

```
epochs = epochs.average()
```

Zprůměrované epochy je možné vidět na obrázku 9.4.



Obrázek 9.4: Zprůměrované veškeré již umocněné epochy z jednoho *.eeg souboru. Celkový počet zprůměrovaných epoch je 55.

Úplně posledním krokem k získání výsledného ERD (viz obrázek 9.5) je aplikování rovnice[4] 9.1.


$$ERD_i(\%) = \frac{Act_i - R}{R} \times 100 \quad (9.1)$$

Act_i představuje námi zprůměrované epochy a hodnotu R lze vypočítat pomocí rovnice 9.2.

$$R = \frac{1}{k+1} \times \sum_{i=r_0}^{k+r_0} Act_i \quad (9.2)$$

Podle rovnice 9.2 lze tvrdit, že hodnota R je vlastně zprůměrování hodnot v intervalu $\langle r_0; r_0 + k \rangle$, což je interval z klidového období právě před vypočítávaným ERD. V našem případě je to tedy čas od -3.5 vteřiny do -2.5 vteřiny před značkou neboli událostí. Při pohledu na zprůměrované epochy (viz obrázek 9.4) a na výsledné ERD (viz obrázek 9.5) se zdají být oba obrázky totožné. Ovšem při bližším prozkoumání osy y je zřejmé že výsledné ERD je *znormálováno* pomocí klidu před ERD a tedy hodnoty se můžou pohybovat v neideálních případech přibližně od -100% do +500%.

Pro lepší zobrazení výsledného ERD je možné pustit nad daty pohyblivé okno, které výsledky zprůměruje a tím i *vyhladí* výsledný graf. Vyhlazení probíhá pomocí následujícího příkazu:



Obrázek 9.5: Výsledné ERD vypočítané z obrázku 9.4

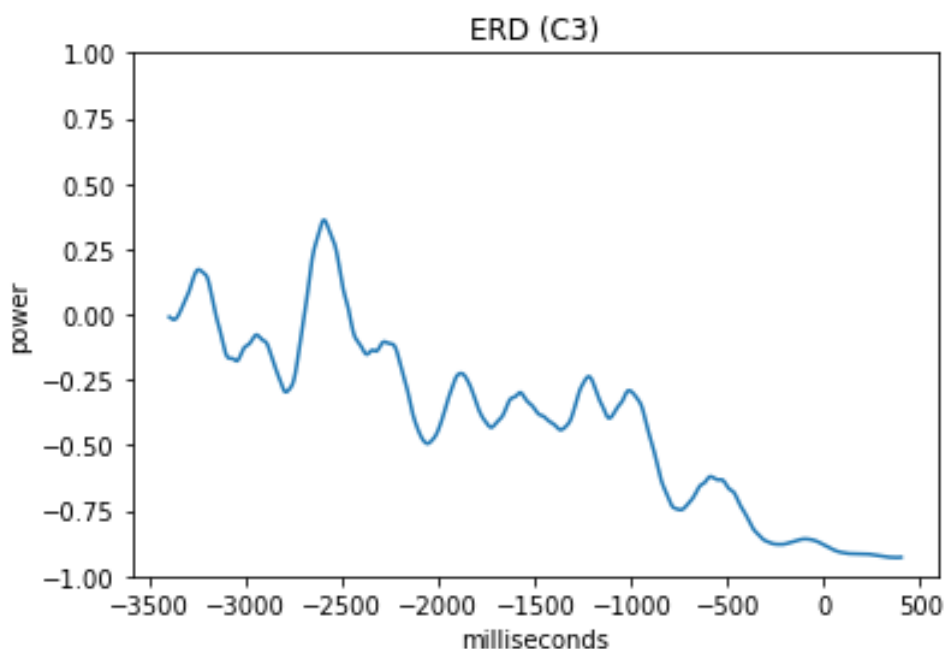
```
df = ERD.to_data_frame()
dfr = df.rolling(window = 100, win_type='triang').mean()
```

Tato dvojice příkazu jen říká, že se vytvoří data frame z výsledného ERD a uloží se do pole `df`, nad kterým se následně funkcí *rolling* vytvoří pohyblivé okno o velikosti 100 vzorků, které vždy zprůměruje a posune se dál. Vyhlazené ERD je možné pozorovat na obrázku 9.5. Je možné si všimnout, že zhruba od -2,5 vteřiny před událostí skutečně vidíme pokles spektrální hodnoty až zhruba do události a tedy lze předpokládat že v grafu je přítomné ERD.

Výpočet ERS probíhá obdobným způsobem jako výpočet ERD. Z toho důvodu nebudu zde zabíhat do extrémně velkých detailů. Nejprve tedy musíme provést filtraci podle frekvence. ERS se ovšem nachází v jiných frekvencích než ERD a tedy musíme provést filtraci ve frekvencích od 14 Hz do 22 Hz. K filtraci těchto dat použijeme stejnou funkci jako při filtraci dat pro ERD, akorát s trošku pozměněnými parametry. Upravený příkaz pak bude vypadat takto:

```
ers.filter(14,22,fir_design="firwin")
```

Po vyfiltrování dat je třeba data umocnit na druhou a stejně jako u ERD vyfiltrovat všechny epochy, které nás zajímají. Získané epochy opět zprůměrujeme a na konec aplikujeme výše zmíněnou rovnici 9.1. Výsledkem tohoto postupu je ERS.



Obrázek 9.6: Vyhlazený graf z obrázku 9.5 pomocí pohyblivého okna (rolling-window) o velikost 100 prvků a průměrování.

9.2 Výpočet ERD a ERS v alfa a beta pásmech

ERD a ERS je možné počítat i v jiných frekvencích. Jedná se o ERD v alfa nebo beta pásmu a o ERS v nižším beta pásmu (lower beta band) nebo ve vyšším beta pásmu (higher beta band). Výpočet probíhá v podstatě totožně jako pro klasické ERD či ERS, ovšem s tím rozdílem, že opět aplikujeme filtraci podle frekvence, ale s trochu jinými parametry. Pro ERD v alfa pásmu je nastavena frekvence od 10 Hz do 12 Hz, pro ERD v Beta pásmu pak frekvence od 20 Hz do 24 Hz. ERS v nižším beta pásmu se vyskytuje mezi 12 Hz a 16 Hz a ve vyšším beta pásmu od 26 Hz do 30 Hz. Upravené příkazy pro filtraci pak budou vypadat následovně:

```
erdAlpha.filter(10,12,fir_design="firwin")
erdBeta.filter(20,24,fir_design="firwin")
ersLBeta.filter(12,16,fir_design="firwin")
ersHBeta.filter(26,30,fir_design="firwin")
```

erdAlpha je proměnná pro ERD počítané v alfa pásmu, erdBeta pro ERD v beta pásmu, ersLBeta pro ERS v nižším beta pásmu a na konec ersHBeta pro ERS počítané ve vyšším beta pásmu.

10 Tvorba příznakových vektorů

Veškeré příznakové vektory jsou vytvářeny pomocí vypočítaného ERD/ERS popřípadě ERD z alfa/beta pásma nebo ERS počítaného z nižšího beta pásma či vyššího beta pásma.

Celkově bylo vypočítáno 7 různých druhů příznakových vektorů:

1. *První vektor* byl zkonstruován kombinací všech hodnot z ERD/ERS takovým způsobem, že nejprve do pole byly vloženy všechny prvky z vypočítaného ERD, za kterými následovaly veškeré prvky z vypočítaného ERS.
2. *Druhý vektor* byl vytvořen velice podobným způsobem jako první vektor, ovšem s tím rozdílem, že bylo použito pouze ERD. Takže ve výsledku byl tento vektor 2x menší než vektor první.
3. *Třetí vektor* byl složen z hodnot vypočítaných z ERD a ERS. Na prvních dvou pozicích je nejprve umístěna průměrná absolutní hodnota (MAV - mean absolute value) z ERD následovaná MAV z ERS. Za tyto dvě hodnoty byl umístěn průměr z ERD, průměr z ERS, rozptyl z ERD, rozptyl z ERS, minimální hodnota z ERD, minimální hodnota z ERS, maximální hodnota z ERD a na konec maximální hodnota z ERS.
4. *Čtvrtý vektor* je skoro totožný jako předchozí vektor jen s tím rozdílem, že za maximální hodnotu z ERS je umístěna fraktální dimenze z ERD a fraktální dimenze z ERS.
5. *Pátý vektor* je vytvořený z příznaků použitých k vytvoření *třetího vektoru* jen s tím rozdílem, že teď jsou příznaky počítány z ERD pro alfa pásmo, ERS pro nižší beta pásmo, ERD pro beta pásmo a ERS pro vyšší beta pásmo. Tento vektor je složen z hodnot, které se umísťují tak, že je vždy uložen jeden příznak z ERD pro alfa pásmo, ERS pro nižší beta pásmo, ERD pro beta pásmo a ERS pro vyšší beta pásmo. Nejprve jsou uloženy hodnoty MAV, poté průměry následované rozptyly a na konec jsou umístěny minimální a maximální hodnoty.
6. *Šestý vektor* je z velké části totožný jako vektor předchozí, ovšem v tomto vektoru jsou za maximální hodnoty vloženy fraktální dimenze

opět z ERD pro alfa pásmo, ERS pro nižší beta pásmo, ERD pro beta pásmo a ERS pro vyšší beta pásmo.

7. *Sedmý vektor* je zkonstruován stejným způsobem, tedy obsahuje postupně hodnoty MAV, průměry, rozptyly, minimální hodnoty, maximální hodnoty a fraktální dimenze. Tyto hodnoty jsou pro tento příznakový vektor počítány z ERD pro alfa pásmo a z ERD pro beta pásmo.

Pro jednoduchost bude dále mluveno pouze o vektorech označených jako *první vektor* až *sedmý vektor*. Ke každému výše popsánému vektoru bylo na konec přidáno jedno číslo, a to buď číslo 1, pokud se jedná o vektor z pohybové fáze a nebo číslo 0, pokud se jedná o vektor z klidové fáze.

První vektor byl vytvořen, protože tato možnost byla nejjednodušší a bylo myšleno jí použít jakožto takový výchozí bod, který je možné zlepšit. V kapitole 13 je možné vidět, že tento příznakový vektor má velmi dobrou úspěšnost, ale kvůli tomu, že jeho dimenze je "obrovská", tak to výrazně zpomalilo celou neuronovou síť. Z tohoto důvodu byl vytvořen *třetí, čtvrtý, pátý* a *šestý* vektor. Tyto vektory byly vytvořené kvůli tomu, že jejich dimenze je oproti *prvnímu* vektoru extrémně malá a to mělo zajistit rychlejší celkovou práci s neuronovou sítí. Jak je řečeno v kapitole 13, tak se čas sice zlepšil, ale přesnost klasifikace nebyla zcela dostačující.

Kvůli extrémnímu poklesu přesnosti byly vymyšleny alternativy k *prvnímu vektoru* tak, že bylo zachováno co nejvíce informace z tohoto vektoru, ale jeho dimenze byla rapidně snížena. Tohoto snížení bylo dosaženo podvzorkováním původního signálu z 500 Hz na 256 Hz, 128 Hz a 64 Hz. Tohoto podvzorkování bylo dosaženo pomocí příkazu:

```
eeg[i].resample(numberOfSamplesPerSecond, npad="auto")
```

Tento příkaz podvzorkuje data uložená v poli *eeg[i]* na frekvenci uloženou v proměnné *numberOfSamplesPerSecond*. Druhý parametr *npad="auto"* je uveden pouze z toho důvodu, aby proběhlo podvzorkování rychleji.

Posledními vytvořenými vektory jsou *druhý* a *sedmý* vektor. Tyto vektory byly vytvořeny pouze kvůli tomu, že v budoucnu se tento použitý rehabilitační robot bude snažit rozpoznávat pohyb pouze na základě ERD nikoli i ERS a z toho důvodu byly tedy vytvořeny tyto dva druhy příznakových vektorů, které se odvíjí od výše popsáných typů a jsou složeny pouze s použitím ERD. *Druhý* vektor byl stejně jako první vektor počítán z původních dat i z dat podvzorkovaných na frekvenci 256 Hz, 128 Hz a 64 Hz.

Jelikož je každý vektor tvořen trochu jiným způsobem, tak je jasné, že každý vektor bude mít i jinou velikost (dimenzi). Pro přehlednost jsou

všechny dimenze použitých vektorů v následující tabulce 10. V těchto dimenzích není započítán poslední prvek příznakových vektorů označující, zda byl vektor počítán z klidové či pohybové fáze.

Označení vektoru	Velikost vektoru
První vektor (500 Hz)	4 002
První vektor (256 Hz)	2 050
První vektor (128 Hz)	1 026
První vektor (64 Hz)	514
Druhý vektor (500 Hz)	2 001
Druhý vektor (256 Hz)	1 025
Druhý vektor (128 Hz)	513
Druhý vektor (64 Hz)	257
Třetí vektor	10
Čtvrtý vektor	12
Pátý vektor	20
Šestý vektor	24
Sedmý vektor	12

Tabulka 10.1: V této tabulce jsou uvedeny velikosti všech použitých příznakových vektorů.

11 Klasifikace pohybu

Nyní, když byly vytvořeny příznakové vektory, tak je možné se pokusit o klasifikaci pohybu neboli o klasifikaci těchto příznakových vektorů. Použitým klasifikátorem je poměrně jednoduchá neuronová síť, která je též implementována v programovacím jazyce Python ve verzi 3.8.5 s využitím modulu Keras. Příznakové vektory jsou nahrány jako trénovací a klasifikační množiny ze souborů `trainXX.csv` a `testXX.csv`, kde `XX` označuje dvojciferné číslo podle toho jaké příznakové vektory chceme zrovna použít. K tomuto načtení ze souborů slouží modul Pandas.

11.1 Modul Keras

Keras je open source knihovna pro neuronové sítě napsaná v jazyce Python, která běží nad modulem Theano nebo Tensorflow. K implementaci neuronové sítě byl zvolen modul Keras, protože je navržen tak, aby byl modulární, rychlý a snadno použitelný. Vyvinul ji François Chollet pracující jakožto inženýr ve společnosti Google. Keras nezvládá výpočty na nízké úrovni. K těmto výpočtům využívá takzvaný "Backend" engine.

Keras je tedy vysokoúrovňový obal API pro nízkoúrovňové API, který je schopen běžet nad CNTK, Theano nebo TensorFlow (v našem případě běží nad modulem TensorFlow). Vysokoúrovňové rozhraní API Keras slouží jako způsob, jakým vytváříme modely, definujeme vrstvy nebo nastavujeme více vstupně-výstupních modelů. Na této úrovni Keras také sestavuje náš model pomocí ztrátových a optimalizačních funkcí. Natrénování neuronové sítě pak probíhá pomocí funkce `fit` a výsledná klasifikace pomocí funkce `evaluate`.

11.2 Modul Pandas

Modul Pandas je stejně jako Keras open source knihovna naprogramovaná v programovacím jazyce Python. Pandas poskytuje připravené vysoce výkonné datové struktury a nástroje pro analýzu dat. Poskytuje také zjednodušené zarovnávání tabulkových dat a výkonné funkce časových řad. Tento modul běží nad modulem NumPy a používá se převážně pro datovou vědu a analýzu dat. NumPy je nízkoúrovňová datová struktura, která podporuje vícerozměrná pole a širokou škálu matematických operací s poli. Z toho i tak trochu vyplývá, že Pandas má rozhraní vyšší úrovně.

Klíčovou datovou strukturou v modulu Pandas je tzv. `DataFrame` umožňující nám ukládat a manipulovat s tabulkovými daty jako s dvourozměrnou datovou strukturou. Klíčová struktura `DataFrame` je využita pro načtení trénovací a testovací množiny příznakových vektorů. Tato načtená data jsou pak krátce zpracována pomocí funkcí, které poskytuje Pandas pro `DataFrame`. Mezi takovéto poskytované funkce patří například zarovnání dat, statistiky dat, rozřezávání, seskupování, slučování nebo spojování dat.

11.3 Neuronová síť

Jak již bylo zmíněno výše, tak neuronová síť byla implementována s pomocí modulu Keras a data byla načtená jako datová struktura `DataFrame` modulu Pandas. Jako model celé neuronové sítě je použit model *Sequential* viz kapitola 11.3.1. Po rozsáhlém testování (viz kapitola 13) byla zvolena síť, obsahující jednu vstupní, tři skryté a jednu výstupní vrstvu. První skrytá vrstva poté obsahuje 400 neuronů, druhá skrytá vrstva 200 neuronů, třetí skrytá vrstva 100 neuronů a výstupní vrstva obsahuje pouze jeden jediný neuron, jelikož potřebujeme vědět pouze to, zda byl nebo nebyl vykonán pohyb, tak právě z toho důvodu nám stačí na výstupu pouze jeden neuron a pozorujeme zda hodnota tohoto neuronu překročí prahovou hodnotu (klasifikováno jako pohyb) nebo nepřekročí (klasifikováno jako klid).

Jako nejlepší aktivační funkce pro tento problém vyšla podle kapitoly 12 funkce sigmoida definovaná předpisem:

$$y(t) = \frac{1}{1 + e^{-v(t)}} \quad (11.1)$$

Byla vyzkoušena i aktivační funkce hyperbolický tangens, ovšem ta nebyla tak úspěšná jako sigmoida.

Práh neuronů byl ponechán tak, jak je nastaven defaultně na hodnotě 0,5. Binary Cross-Entropy byla použita jako ztrátová funkce, převážně z důvodu, že se v našem případě jedná právě o binární neuronovou síť, kvůli tomu, že výstupní vrstva obsahuje pouze jediný neuron.


Jak již vyplývá z použitého sekvenčního modelu, jedná se o dopřednou neuronovou síť, která využívá učící algoritmus back propagation (viz kapitola 4.2.3) s počtem iterací¹ nastaveným na hodnotu 100. Učící algoritmus back propagation je nastaven defaultně modulem Keras a tedy není třeba ho nějak speciálně nastavovat.

¹V příloženém zdrojovém kódu je místo použito označení epocha, což je alternativní označení pro iteraci

11.3.1 Model neuronové sítě

Pokud je neuronová síť vytvářena pomocí modulu Keras, tak jsou možné pouze dva modely neuronové sítě.

Prvním typem je typ sekvenční (viz obrázek), umožňující vytvářet jednoduše vrstvu za vrstvou. Nejjednodušším způsobem jak si tento model definovat je představit si jednoduché jednorozměrné pole, kde na indexu 0 je vstupní vrstva neuronové sítě, na indexu 1 - n jsou skryté vrstvy (n je počet skrytých vrstev) a na indexu n+1 je poslední výstupní vrstva.



Obrázek 11.1: Ilustrace sekvenčního modelu, který obsahuje jednu vstupní vrstvu, jednu výstupní vrstvu a 3 skryté vrstvy.

Alternativním modelem je funkční model, umožňující naopak vytvářet modely, které mají mnohem větší flexibilitu, protože je možné snadno definovat modely, v nichž se vrstvy připojují k více než jen k předchozí a následující vrstvě. Ve skutečnosti v tomto modelu je možné propojit vrstvy s doslova jakoukoli jinou vrstvou. Díky této vlastnosti je možné vytvářet například tzv. rekurentní sítě.

12 Testování

Veškeré testování probíhalo na stolním počítači osazeným 16GB operační pamětí HyperX 16GB DDR4 3200 MHz CL18 Fury Black Series a šesti jádrovým procesorem AMD Ryzen 5 1600X, 3,6 GHz. Všechny zdrojové soubory, které jsou součástí této diplomové práce byly napsány v programovacím jazyce Python ve verzi 3.8.5 s použitím výše zmíněných modulů (viz kapitola 9 a kapitola 11).

Předzpracování dat bylo podrobně zkoumáno krok za krokem a bylo zjišťováno, zda výpočty probíhají korektně. Stejným způsobem bylo pozorováno, zda probíhá správně i výpočet ERD/ERS a následně i výpočet všech příznakových vektorů. To, že výpočty probíhají korektně, také trochu indikuje to, že na obrázku 9.5 lze pozorovat přítomnost ERD, tudíž lze považovat výpočet ERD za úspěšný.

Neuronová síť byla vždy 100x spouštěna s mnoha různými parametry na poměrně velkém počtu rozdílných příznakových vektorů (viz kapitola 10). Z těchto 100 výsledků byla poté spočítána průměrná, minimální a maximální přesnost klasifikace a průměrný čas potřebný pro práci s danou neuronovou sítí. Tímto způsobem bylo zjišťováno optimální nastavení neuronové sítě pro každou skupinu příznakových vektorů. Podrobný popis většiny dosažených výsledků je uveden v následující kapitole 13.

13 Dosažené výsledky

Všechny příznakové vektory, které byly vytvořeny (viz kapitola 10), tak byly použity jako vstupní trénovací a klasifikační množina do implementované neuronové sítě, ve které se nadále "hrálo" s parametry jako je například aktivační funkce, počet neuronů v jednotlivých skrytých vrstvách nebo počet těchto skrytých vrstev. Klasifikováno bylo mnohem více příznakových vektorů než je uvedeno v kapitole 10, ovšem klasifikace těchto příznakových vektorů se pohybovala okolo 50%, což v našem případě, když klasifikujeme, zda byl nebo nebyl vykonán pohyb, znamená, že bychom místo umělé neuronové sítě mohli použít generátor náhodných čísel, který by náhodně klasifikoval tyto příznakové vektory a pravděpodobnost takové klasifikace by se též pohybovala okolo 50%. Z tohoto důvodu nejsou tyto příznakové vektory v této práci podrobně popsány a ani zde není možné nalézt výsledky z jejich klasifikování. Jednalo se především o příznakové vektory, jež byly konstruovány například z ERD pro alfa pásmo a z ERS pro nižší beta pásmo nebo z ERD pro beta pásmo a z ERS pro vyšší beta pásmo.

Veškeré dosažené výsledky lze najít v tabulce 13.1 až v tabulce 13.13. Každá níže vypsaná tabulka obsahuje výsledky klasifikace umělou neuronovou sítí pro jeden příznakový vektor. Všechny níže uvedené tabulky mají totožnou strukturu. První čtyři sloupce udávají nastavení právě použité umělé neuronové sítě. Z toho první tři sloupce ukazují kolik neuronů bylo v první, druhé a třetí skryté vrstvě. Pokud tento počet neuronů se rovná 0, tak to znamená, že v daném nastavení tato skrytá vrstva nebyla. Ve finále to tedy znamená, že první 4 záznamy jsou z neuronové sítě, která obsahovala pouze jednu jedinou skrytou vrstvu, další 4 záznamy jsou z neuronové sítě, která obsahoval 2 skryté vrstvy a poslední 4 záznamy jsou z neuronové sítě, obsahující 3 skryté vrstvy. Čtvrtý sloupec v tabulce ukazuje jaká aktivační funkce byla použita. Byly zkoumány výsledky pomocí dvou aktivačních funkcí, a to funkce *sigmoid* a funkce *hyperbolický tangens*. Druhá polovina sloupců v tabulce je určena pro výsledky získané z klasifikace. První sloupec z této poloviny říká, jaká byla průměrná přesnost klasifikace s daným nastavením neuronové sítě. Další sloupec znázorňuje minimální přesnost, jaké bylo dosaženo při klasifikaci. Následuje jej sloupec naopak s maximální přesností. Poslední sloupec zobrazuje čas v sekundách, který je potřebný pro sestavení a natrénování jedné neuronové sítě a následnou klasifikaci testovací množiny.

Z tabulek 13.1 až 13.8 je zřejmé, že pro první dva vektory je nejpřesnější klasifikace neuronovou sítí, která obsahuje 3 skryté vrstvy, kde v první je 400

neuronů, ve druhé 200 neuronů a ve třetí 100 neuronů. Pokud tyto neurony obsahovaly aktivační funkci sigmoid, tak se přesnost klasifikátoru pohybovala mezi 84,95% až 90,05% což je největší dosažená přesnost v této práci. Jelikož rehabilitační robot bude klasifikovat pouze z ERD, tak pro online klasifikaci by na základě těchto výsledků bylo nejvhodnější zvolit *druhý* vektor, který byl počítán z podvzorkovaného signálu na 128 Hz. Se správným nastavením je neuronová síť schopná klasifikovat tento vektor s přesností přibližně 86,30%, což není vůbec špatný výsledek a čas potřebný pro práci s takto nastavenou sítí je něco pod 2 sekundy.

V následujících tabulkách 13.9 až 13.13 jsou zobrazeny výsledky klasifikace *třetího* až *sedmého* příznakového vektoru. Tyto výsledky jsou o něco nižší než u předchozích výsledků, ovšem čas potřebný pro práci s těmito neuronovými sítěmi je též velmi nižší. Co se týče *třetího* a *čtvrtého* příznakového vektoru, tak zde byla největší dosažená přesnost klasifikace neuronovou sítí obsahující aktivační funkci sigmoid a pouze jednu jedinou skrytou vrstvu s počtem neuronů rovným 200. Tato přesnost byla přibližně 68,35% u *třetího* a 68,50% u *čtvrtého* příznakového vektoru. Čas potřebný pro práci s těmito neuronovými sítěmi se pohyboval okolo 1,3 sekundy, což je dle výsledků jeden z nejlepších dosažených časů. U zbylých třech příznakových vektorů bylo dosaženo nejlepší přesnosti pomocí neuronové sítě obsahující dvě skryté vrstvy, kde první skrytá vrstva obsahuje 200 neuronů a druhá skrytá vrstva obsahuje 100 neuronů. S tímto nastavením bylo dosaženo přesnosti od 60,77% do 66,92%. Čas potřebný pro práci s neuronovou sítí je přibližně okolo 1,4 sekundy. Přesnost klasifikace *pátého* a *šestého* příznakového vektoru je s tímto nastavením přibližně o 1,5% nižší a čas je přibližně o 0,1 sekundy větší než u *třetího* a *čtvrtého* vektoru. Z toho důvodu lze tvrdit, že *třetí* a *čtvrtý* příznakový vektor je lepší pro klasifikaci než *pátý*, *šestý* a *sedmý* vektor. *Sedmý* vektor dosahuje nejmenší přesnosti klasifikace těchto vektorů kvůli tomu, že byl vytvořen pro online klasifikaci při měření a tedy je konstruován pouze pomocí ERD nikoli i ERS. Bohužel přesnost klasifikace tohoto vektoru je tak malá, že vhodnější bude použít pro online klasifikaci *druhý* příznakový vektor.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	86,55%	77,50%	97,50%	2,6791
100	0	0	Tanh	79,02%	17,50%	95,00%	2,7110
200	0	0	Sigmoid	85,68%	77,50%	97,50%	3,3159
200	0	0	Tanh	81,15%	20,00%	95,00%	3,5258
200	100	0	Sigmoid	89,62%	80,00%	97,50%	3,5193
200	100	0	Tanh	82,70%	60,00%	92,50%	3,5656
400	200	0	Sigmoid	87,45%	77,50%	92,50%	5,0781
400	200	0	Tanh	83,23%	70,00%	92,50%	5,0008
400	200	100	Sigmoid	89,90%	82,50%	97,50%	5,7965
400	200	100	Tanh	81,75%	20,00%	92,50%	5,1889
800	400	200	Sigmoid	89,45%	82,50%	95,00%	10,0412
800	400	200	Tanh	83,48%	57,50%	95,00%	9,2974

Tabulka 13.1: Výsledky klasifikace prvních příznakových vektorů vzorkovaných na 500 Hz (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	86,27%	75,00%	97,50%	1,8839
100	0	0	Tanh	81,35%	55,00%	95,00%	1,9784
200	0	0	Sigmoid	84,33%	72,50%	95,00%	2,3941
200	0	0	Tanh	79,65%	15,00%	90,00%	2,4958
200	100	0	Sigmoid	88,05%	80,00%	97,50%	2,6193
200	100	0	Tanh	82,65%	65,00%	95,00%	2,6115
400	200	0	Sigmoid	87,88%	80,00%	97,50%	3,8825
400	200	0	Tanh	82,23%	30,00%	92,50%	3,8025
400	200	100	Sigmoid	89,97%	82,50%	95,00%	3,7134
400	200	100	Tanh	82,48%	47,50%	95,00%	3,7034
800	400	200	Sigmoid	88,95%	82,50%	95,00%	6,2564
800	400	200	Tanh	81,20%	15,00%	95,00%	6,4480

Tabulka 13.2: Výsledky klasifikace prvních příznakových vektorů vzorkovaných na 256 Hz (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	85,43%	72,50%	92,50%	1,6494
100	0	0	Tanh	78,70%	22,50%	90,00%	1,7235
200	0	0	Sigmoid	85,83%	72,50%	95,00%	1,7181
200	0	0	Tanh	81,10%	55,00%	95,00%	1,8013
200	100	0	Sigmoid	87,65%	77,50%	95,00%	1,9340
200	100	0	Tanh	81,55%	62,50%	90,00%	1,8325
400	200	0	Sigmoid	88,97%	80,00%	95,00%	2,7573
400	200	0	Tanh	81,62%	37,50%	97,50%	2,6358
400	200	100	Sigmoid	90,05%	82,50%	97,50%	2,7416
400	200	100	Tanh	80,30%	17,50%	95,00%	2,7529
800	400	200	Sigmoid	89,70%	82,50%	97,50%	4,2096
800	400	200	Tanh	81,03%	20,00%	92,50%	4,2436

Tabulka 13.3: Výsledky klasifikace prvních příznakových vektorů vzorkovaných na 128 Hz (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	84,43%	70,00%	95,00%	1,4908
100	0	0	Tanh	77,30%	15,00%	92,50%	1,5685
200	0	0	Sigmoid	84,62%	70,00%	95,00%	1,5719
200	0	0	Tanh	77,90%	17,50%	87,50%	1,6531
200	100	0	Sigmoid	87,45%	80,00%	97,50%	1,6626
200	100	0	Tanh	79,35%	20,00%	92,50%	1,6795
400	200	0	Sigmoid	87,15%	80,00%	95,00%	1,9378
400	200	0	Tanh	80,48%	17,50%	90,00%	2,0121
400	200	100	Sigmoid	88,70%	82,50%	95,00%	2,0134
400	200	100	Tanh	81,70%	67,50%	95,00%	2,0917
800	400	200	Sigmoid	88,90%	82,50%	95,00%	3,2943
800	400	200	Tanh	80,50%	15,00%	92,50%	3,3180

Tabulka 13.4: Výsledky klasifikace prvních příznakových vektorů vzorkovaných na 64 Hz (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	81,82%	67,50%	95,00%	1,8300
100	0	0	Tanh	78,58%	10,00%	92,50%	1,8816
200	0	0	Sigmoid	80,15%	67,50%	90,00%	2,3859
200	0	0	Tanh	78,40%	7,50%	92,50%	2,4937
200	100	0	Sigmoid	82,80%	75,00%	90,00%	3,3713
200	100	0	Tanh	78,95%	12,50%	90,00%	2,6256
400	200	0	Sigmoid	83,20%	75,00%	90,00%	3,4547
400	200	0	Tanh	79,95%	12,50%	92,50%	3,7500
400	200	100	Sigmoid	86,73%	80,00%	92,50%	3,5706
400	200	100	Tanh	79,75%	12,50%	90,00%	4,0153
800	400	200	Sigmoid	85,40%	80,00%	92,50%	6,5836
800	400	200	Tanh	79,95%	10,00%	90,00%	6,7067

Tabulka 13.5: Výsledky klasifikace druhých příznakových vektorů vzorkovaných na 500 Hz (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	81,23%	67,50%	90,00%	1,6254
100	0	0	Tanh	78,03%	20,00%	90,00%	1,6714
200	0	0	Sigmoid	79,57%	70,00%	90,00%	1,6890
200	0	0	Tanh	76,95%	10,00%	90,00%	1,7375
200	100	0	Sigmoid	83,50%	72,50%	95,00%	1,8117
200	100	0	Tanh	78,53%	17,50%	92,50%	1,9456
400	200	0	Sigmoid	82,45%	75,00%	90,00%	2,6592
400	200	0	Tanh	79,75%	45,00%	92,50%	2,7046
400	200	100	Sigmoid	85,85%	80,00%	92,50%	2,5219
400	200	100	Tanh	80,75%	67,50%	90,00%	2,7781
800	400	200	Sigmoid	85,28%	77,50%	90,00%	4,1490
800	400	200	Tanh	79,22%	17,50%	90,00%	4,3828

Tabulka 13.6: Výsledky klasifikace druhých příznakových vektorů vzorkovaných na 256 Hz (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	79,78%	70,00%	92,50%	1,4661
100	0	0	Tanh	77,60%	15,00%	92,50%	1,5375
200	0	0	Sigmoid	79,60%	65,00%	90,00%	1,5448
200	0	0	Tanh	78,50%	15,00%	92,50%	1,6103
200	100	0	Sigmoid	83,73%	72,50%	92,50%	1,6356
200	100	0	Tanh	78,97%	25,00%	92,50%	1,7175
400	200	0	Sigmoid	82,65%	70,00%	90,00%	1,9217
400	200	0	Tanh	78,40%	15,00%	92,50%	2,0593
400	200	100	Sigmoid	86,30%	80,00%	92,50%	1,9602
400	200	100	Tanh	78,45%	17,50%	92,50%	2,0970
800	400	200	Sigmoid	86,13%	80,00%	92,50%	3,2843
800	400	200	Tanh	78,25%	15,00%	92,50%	3,2900

Tabulka 13.7: Výsledky klasifikace druhých příznakových vektorů vzorkovaných na 128 Hz (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	80,22%	67,50%	90,00%	1,4082
100	0	0	Tanh	76,45%	12,50%	92,50%	1,4601
200	0	0	Sigmoid	78,95%	67,50%	87,50%	1,4439
200	0	0	Tanh	76,00%	15,00%	87,50%	1,5122
200	100	0	Sigmoid	82,13%	75,00%	90,00%	1,5438
200	100	0	Tanh	76,47%	15,00%	87,50%	1,5977
400	200	0	Sigmoid	82,33%	72,50%	90,00%	1,7937
400	200	0	Tanh	76,38%	17,50%	87,50%	1,8538
400	200	100	Sigmoid	84,95%	80,00%	90,00%	1,7984
400	200	100	Tanh	77,45%	32,50%	95,00%	1,9740
800	400	200	Sigmoid	83,65%	77,50%	92,50%	2,7432
800	400	200	Tanh	79,08%	17,50%	90,00%	2,7189

Tabulka 13.8: Výsledky klasifikace druhých příznakových vektorů vzorkovaných na 64 Hz (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	67,52%	55,00%	77,50%	1,3110
100	0	0	Tanh	49,90%	37,50%	62,50%	1,3836
200	0	0	Sigmoid	68,35%	57,50%	77,50%	1,3065
200	0	0	Tanh	50,15%	50,00%	65,00%	1,3587
200	100	0	Sigmoid	63,40%	55,00%	72,50%	1,4381
200	100	0	Tanh	49,95%	45,00%	50,00%	1,5011
400	200	0	Sigmoid	66,42%	55,00%	72,50%	1,5889
400	200	0	Tanh	49,88%	37,50%	50,00%	1,5899
400	200	100	Sigmoid	59,77%	55,00%	72,50%	1,6724
400	200	100	Tanh	50,00%	50,00%	50,00%	1,6950
800	400	200	Sigmoid	61,15%	50,00%	72,50%	2,3783
800	400	200	Tanh	50,00%	50,00%	50,00%	2,4049

Tabulka 13.9: Výsledky klasifikace třetích příznakových vektorů (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	67,73%	52,50%	77,50%	1,2875
100	0	0	Tanh	49,85%	42,50%	65,00%	1,3648
200	0	0	Sigmoid	68,50%	57,50%	75,00%	1,2958
200	0	0	Tanh	50,05%	47,50%	55,00%	1,3738
200	100	0	Sigmoid	63,70%	55,00%	70,00%	1,4148
200	100	0	Tanh	49,97%	47,50%	50,00%	1,4444
400	200	0	Sigmoid	66,30%	57,50%	72,50%	1,5733
400	200	0	Tanh	49,88%	40,00%	50,00%	1,6109
400	200	100	Sigmoid	59,88%	47,50%	72,50%	1,6830
400	200	100	Tanh	50,00%	50,00%	50,00%	1,7236
800	400	200	Sigmoid	61,20%	50,00%	72,50%	2,3806
800	400	200	Tanh	50,00%	50,00%	50,00%	2,4423

Tabulka 13.10: Výsledky klasifikace čtvrtých příznakových vektorů (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	62,15%	47,50%	80,00%	1,2982
100	0	0	Tanh	51,50%	37,50%	67,50%	1,3727
200	0	0	Sigmoid	60,98%	50,00%	77,50%	1,3130
200	0	0	Tanh	51,12%	32,50%	72,50%	1,3787
200	100	0	Sigmoid	66,43%	57,50%	80,00%	1,4325
200	100	0	Tanh	51,22%	30,00%	67,50%	1,4769
400	200	0	Sigmoid	65,30%	52,50%	77,50%	1,5991
400	200	0	Tanh	50,53%	47,50%	72,50%	1,6319
400	200	100	Sigmoid	64,50%	47,50%	77,50%	1,7125
400	200	100	Tanh	50,72%	45,00%	67,50%	1,7327
800	400	200	Sigmoid	63,08%	47,50%	77,50%	2,3946
800	400	200	Tanh	50,40%	47,50%	70,00%	2,4168

Tabulka 13.11: Výsledky klasifikace pátých příznakových vektorů (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	61,62%	47,50%	75,00%	1,3259
100	0	0	Tanh	52,37%	40,00%	75,00%	1,3667
200	0	0	Sigmoid	60,78%	50,00%	75,00%	1,3148
200	0	0	Tanh	50,82%	42,50%	75,00%	1,3797
200	100	0	Sigmoid	66,92%	52,50%	77,50%	1,4058
200	100	0	Tanh	51,47%	42,50%	65,00%	1,5001
400	200	0	Sigmoid	64,92%	52,50%	75,00%	1,5835
400	200	0	Tanh	50,80%	35,00%	67,50%	1,6179
400	200	100	Sigmoid	63,45%	47,50%	77,50%	1,6942
400	200	100	Tanh	51,08%	47,50%	67,50%	1,7517
800	400	200	Sigmoid	63,27%	50,00%	77,50%	2,4232
800	400	200	Tanh	50,12%	45,00%	70,00%	2,4448

Tabulka 13.12: Výsledky klasifikace šestých příznakových vektorů (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

1.	2.	3.	Acti. f.	Avg. acc.	Min. acc.	Max. acc.	Čas [s]
100	0	0	Sigmoid	59,87%	45,00%	67,50%	1,2939
100	0	0	Tanh	50,45%	45,00%	60,00%	1,3365
200	0	0	Sigmoid	59,65%	50,00%	67,50%	1,2929
200	0	0	Tanh	50,15%	45,00%	55,00%	1,3320
200	100	0	Sigmoid	60,77%	50,00%	67,50%	1,4235
200	100	0	Tanh	50,17%	42,50%	55,00%	1,4614
400	200	0	Sigmoid	58,77%	47,50%	65,00%	1,5759
400	200	0	Tanh	49,97%	45,00%	52,50%	1,6063
400	200	100	Sigmoid	58,65%	47,50%	70,00%	1,6271
400	200	100	Tanh	49,95%	47,50%	50,00%	1,7386
800	400	200	Sigmoid	56,27%	47,50%	67,50%	2,3764
800	400	200	Tanh	49,95%	45,00%	50,00%	

Tabulka 13.13: Výsledky klasifikace sedmých příznakových vektorů (viz kapitola 10). Podrobný popis tabulky v kapitole 13.

14 Závěr

Tato diplomová práce splňuje všechny body zadání. Vhodný scénář pro měření EEG dat na rehabilitačním robotovi byl úspěšně navržen a následně použit při měření EEG na čtrnácti různých lidech. Získaná EEG data byla úspěšně převedena na tzv. ERD/ERS (event related desynchronization a event related synchronization). Z těchto vypočítaných ERD/ERS bylo zkonstruováno 7 typů příznakových vektorů a 2 z nich mají dokonce 4 varianty, díky podvzorkování původního signálu z 500 Hz na 256 Hz, 128 Hz a 64 Hz. Všechny vytvořené příznakové vektory byly použity jako vstupní množina do implementované neuronové sítě, která při vhodném nastavení je schopna tyto příznakové vektory klasifikovat až s přesností 90,05 %.

Samotné měření by mohlo být vylepšeno přidáním virtuální reality. Měřená osoba totiž sice sedí na pohodlné židli, ale hlavu má pořád jemně zakloněnou, aby viděla na obrazovku, kde je zobrazena kruhová trajektorie pohybu. V této poloze není vhodné sedět déle jak 15 minut bez jediného protažení. Z toho důvodu měřené osoby měly tendence se převážně v klidových fázích všemožně protahovat, což jak je zřejmé není zcela vhodné, když v klidové fázi mají sedět naprosto nehybně. Tohoto problému by se právě dalo předejít použitím virtuální reality. Trajektorie pohybu by se poté promítala jak na obrazovku, tak do virtuální reality. Měřená osoba by se tedy mohla posadit tak, jak je jí to nejpohodlnější a dívat se například přímo před sebe. Je velice pravděpodobné, že tímto doplňkem by se přesnost klasifikace ještě o kousek zlepšila.

Z výsledků (viz kapitola 13) je zřejmé, že umělá neuronová síť je vhodný klasifikátor pro klasifikování pohybu v EEG datech pomocí ERD/ERS. Jistě by bylo možné použít umělou neuronovou síť i k online klasifikaci (tj. klasifikace přímo při průběhu měření). Ovšem k online klasifikaci by bylo vhodné naměřit mnohem více lidí než pouze čtrnáct, aby měl klasifikátor daleko větší trénovací množinu. Pomocí této množiny by se klasifikátor natrénoval a v průběhu měření by se pouze převáděl aktuálně získaný EEG signál na ERD, ze kterého by se vypočítal *druhý* nebo *sedmý* příznakový vektor (viz kapitola 10), který by už bylo jednoduché klasifikovat.

Přehled zkratk

Ag/AgCl	Označení elektrod
ANN	Umělá neuronová síť
API	Application Programming Interface
ARM	Asistenční robotický manipulátor
ART	Pokročilé rehabilitační technologie
BAEP	Sluchové evokované potenciály
BP	Bereitschaftspotential
BPTT	Back-propagation through time
BWSTT	Body Weight Support nad Treadmill Training
EEG	Elektroencefalografie
EKG	Elektrokardiografie
EP	Evokované potenciály
ERD	Event related desynchronization
ERP	Event-related potentials
ERS	Event related synchronization
MAV	průměrná absolutní hodnota
MEG	Magnetoencefalografie
MEP	Motorické evokované potenciály
SEP	Somatosenzorické evokované potenciály
VEP	Zrakové evokované potenciály
VR	Virtuální realita

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] ERFANIAN, A. – GERIVANY, M. EEG signals can be used to detect the voluntary hand movements by using an enhanced resource-allocating neural network. *2001 Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 2001, 2001, s. 721–724. doi: 10.1109/IEMBS.2001.1019042. Dostupné z: <http://ieeexplore.ieee.org/document/1019042/>.
- [3] 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>.
- [4] 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>.
- [5] KATZ, M. J. Fractals and the analysis of waveforms. *Computers in Biology and Medicine*. 1988, 18, 3, s. 145–156. ISSN 00104825. doi: 10.1016/0010-4825(88)90041-8. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/0010482588900418>.
- [6] 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>.
- [7] KUMAR, J. S. – BHUVANESWARI, P. Analysis of Electroencephalography (EEG) Signals and Its Categorization—A Study. *Procedia Engineering*. 2012, 38, s. 2525–2536. ISSN 18777058. doi: 10.1016/j.proeng.2012.06.298. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1877705812022114>.

- [8] 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/>.
- [9] LUCK, S. J. *An introduction to the event-related potential technique*. The MIT Press, second edition edition, 2014. ISBN 978-026-2525-855.
- [10] 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.
- [11] 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.
- [12] 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>.
- [13] 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>.
- [14] 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>.
- [15] 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>.
- [16] 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>.

- [17] 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/>.
- [18] 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>.
- [19] 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	76
Příloha B: Obsah ZIP souboru	77
Příloha C: Seznam obrázků	79
Příloha D: Seznam tabulek	79

A Uživatelská příručka

V této příloze je vysvětlen kompletní postup pro spuštění obou aplikací a je zde uveden postup, jak je možné vykreslit grafy zobrazené v kapitole 9.

A.1 Spuštění aplikace

Obě aplikace jsou vyvíjeny a testovány v pythonu ve verzi 3.8.5 a z toho důvodu je vhodné, pro zajištění správné funkčnosti, pouštět obě aplikace v této verzi. Ke spuštění je také třeba mít nainstalovány potřebné balíky. Pro předzpracování dat je třeba nainstalovat balíky *numpy*, *mne*, *math* a *csv*. Pro následné klasifikování se jedná o balíky *numpy*, *pandas*, *time* a *keras*.

Po nainstalování těchto balíčků stačí pouze zapnout soubor *erders.bat* pro předzpracování dat, který vygeneruje soubory *train01.csv* až *train07.csv* a soubory *test01.csv* až *test07.csv*. Poté je možné spustit druhou aplikaci zapnutím souboru *unn.bat*. Jako defaultní vstupní soubory jsou nastaveny *train01.csv* a *test01.csv*. Pokud chcete změnit tyto vstupní hodnoty, je nutné přepsat "train01.csv" a "test01.csv" na příslušné požadované soubory na 17 a 24 řádku v souboru *unn.py*.

A.2 Vykreslení grafů

Pro vykreslení grafů v kapitole 9 je třeba pouze odkomentovat/zakomentovat nějaké řádky.

Aby program vykreslil obrázek 9.1, je nutné odkomentovat řádky 244-249 a zakomentovat řádky 237 a 238. Pokud poté chcete vykreslit graf na obrázku 9.2 stačí pouze odkomentovat řádek 237 a pro obrázek 9.3 je to navíc řádek 238. Pro vykreslení zprůměrovaných epoch na obrázku 9.4 je třeba odkomentovat řádek 77. Obrázek 9.5 získáme odkomentováním řádku 324-326 a poslední obrázek 9.6 je třeba odkomentovat řádky 329-336. Všechny výše zmíněné grafy byly vypočítány z EEG dat uložených v souboru *z19vbrh1.vhdr*

B Obsah ZIP souboru

K práci je přiloženo ZIP soubor s následující strukturou:

- Aplikace_a_knihovny - Obsahuje zdrojové soubory unn.py a erders.py. Také obsahuje spouštěcí skripty k oběma souborům s názvem unn.bat a erders.bat. Obsahuje také soubor Readme.txt, ve kterém jsou všechny potřebné informace k spuštění aplikací.
- Poster - Obsahuje oba soubory posteru (.pub a .pdf).
- Text_prace - Obsahuje všechny "zdrojové"soubory včetně pdf. Dále obsahuje adresář img, ve kterém jsou uloženy všechny použité obrázky v diplomové práci.
- Vstupni_data - Obsahuje složku EEG, ve kterou jsou uloženy všechny vstupní EEG data.
- Vysledky - Obsahuje všechny vytvořené příznakové vektory uložené do různých trénovacích a testovacích množin. Dále obsahuje vygenerované grafy ERD.

C Seznam obrázků

2.1	Systém 10-20. Zdroj: http://eegbiofeedback.cz	11
2.2	VEP. Zdroj: https://www.enlneuro.com	13
2.3	BAEP. Zdroj: https://www.researchgate.net	14
2.4	SEP. Zdroj: http://www.neurophys.org	15
3.1	BP. Zdroj: https://www.researchgate.net	17
3.2	Generování indukovaných ERD/ERS a ERP. Zdroj: [16]	19
3.3	Výpočet ERD/ERS. Zdroj: [16]	21
3.4	Distribuce ERD. Zdroj: [16]	22
4.1	Model neuronu. Zdroj: https://www.researchgate.net	25
4.2	Model UNN. Zdroj: http://sciencious.com	26
4.3	Rekurentní UNN. Zdroj: https://tex.stackexchange.com	28
4.4	Konvoluční UNN. Zdroj: https://www.researchgate.net	29
5.1	Lokomat. Zdroj: https://www.medicalexpo.com	32
5.2	Arneo Power. Zdroj: https://www.medicalexpo.com	33
5.3	Manovo Power. Zdroj: https://www.medicalexpo.com	34
5.4	Gait Trainer. Zdroj: http://thietbidongy.com	36
5.5	HapticMaster VR. Zdroj: https://www.researchgate.net	36
6.1	Postup. Zdroj: Foto autor	37
7.1	Scénář. Zdroj: Foto autor	39
8.1	Obrazovka. Zdroj: Foto autor	41
8.2	Rehabilitační robot. Zdroj: Foto autor	42
8.3	Ovládání robota. Zdroj: Foto autor	45
8.4	V-Amp. Zdroj: Foto autor	46
8.5	EEG čepice. Zdroj: Foto autor	46
9.1	Epocha. Zdroj: Foto autor	48
9.2	Vyfiltrovaná epocha. Zdroj: Foto autor	49
9.3	Umocněná epocha. Zdroj: Foto autor	50
9.4	Zprůměrované epochy. Zdroj: Foto autor	51
9.5	ERD. Zdroj: Foto autor	52
9.6	Vyhlazené ERD. Zdroj: Foto autor	53
11.1	Sekvenční model. Zdroj: https://livebook.manning.com	59

D Seznam tabulek

2.1	Typy EEG pásem	10
10.1	Dimenze vektorů	56
13.1	Výsledky z prvního vektoru (500 Hz)	63
13.2	Výsledky z prvního vektoru (256 Hz)	63
13.3	Výsledky z prvního vektoru (128 Hz)	64
13.4	Výsledky z prvního vektoru (64 Hz)	64
13.5	Výsledky z druhého vektoru (500 Hz)	65
13.6	Výsledky z druhého vektoru (256 Hz)	65
13.7	Výsledky z druhého vektoru (128 Hz)	66
13.8	Výsledky z druhého vektoru (64 Hz)	66
13.9	Výsledky ze třetího vektoru	67
13.10	Výsledky ze čtvrtého vektoru	67
13.11	Výsledky z pátého vektoru	68
13.12	Výsledky z šestého vektoru	68
13.13	Výsledky ze sedmého vektoru	69