

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

FAKULTA ELEKTROTECHNICKÁ
KATEDRA TEORIE OBVODŮ



Zpracování signálů z inerciálních senzorů za účelem stanovení míry tremoru

Diplomová práce

Michaela Stehlíková

Praha, květen 2024

Studijní program: Lékařská elektronika a bioinformatika
Specializace: Zpracování signálů

Vedoucí: Ing. Jan Havlík, Ph.D.

Poděkování

Děkuji vedoucímu mé diplomové práce Ing. Janu Havlíkovi, Ph.D. za podnětné rady a odbornou pomoc, kterou mi poskytoval při zpracovávání mé diplomové práce, a za čas, který mi věnoval.

Dále tímto děkuji také své rodině a blízkým, kteří mě podporovali nejen při vytváření této práce, ale i po celou dobu mého studia, a bez jejichž pomoci by nebylo možné práci dokončit.

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: Stehlíková Jméno: Michaela Osobní číslo: 492240
Fakulta/ústav: Fakulta elektrotechnická
Zadávající katedra/ústav: Katedra teorie obvodů
Studijní program: Lékařská elektronika a bioinformatika
Specializace: Zpracování signálů

II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

Zpracování signálů z inerciálních sensorů za účelem stanovení míry tremoru

Název diplomové práce anglicky:

Analysis of Signals from Inertial Sensors and Objective Examination of the Tremor

Pokyny pro vypracování:

1. Seznamte se s problematikou klasifikace třesu (tremoru), možnostmi vyšetření tremoru u pacientů s roztroušenou sklerózou a možnostmi využití inerciálních (akcelerometrických a gyrokopických) sensorů pro diagnostiku této nemoci.
2. Navrhněte a implementujte algoritmy signálového zpracování umožňující stanovení míry tremoru ze signálů pořízených inerciálním sensorem.
3. Ověřte použitelnost navržených algoritmů na reálných datech.

Seznam doporučené literatury:

- [1] Marcus Koch, Jop Mostert, Dorothea Heersema, and Jacques De Keyser: Tremor in multiple sclerosis. Journal of Neurology, vol. 254, no. 2, pp. 133 - 145, 2007.
- [2] S. H. Alusi, S. Glickman, T. Z. Aziz, and P. G. Bain: Tremor in multiple sclerosis. Journal of neurology, neurosurgery, and psychiatry, vol. 66, no. 2, pp. 131 - 134, February 1999.
- [3] Paula Pascoal-Faria, Miguel Patrcio, Adriana Leal, Francisco Caramelo, Antnio Freire, Cristina Janurio, and Miguel Castelo-Branco: Understanding tremor in rapid upper limb movements using 3D accelerometers data. Neuroscience and Medicine, vol. 5, no. 5, pp. 205-213, 2014.
- [4] Brian Barkley Graham: Using an accelerometer sensor to measure human hand motion. Master Theses, Massachusetts Institute of Technology, May 11 2000.

Jméno a pracoviště vedoucí(ho) diplomové práce:

Ing. Jan Havlík, Ph.D. katedra teorie obvodů FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: **06.02.2024**

Termín odevzdání diplomové práce: _____

Platnost zadání diplomové práce: **21.09.2025**

Ing. Jan Havlík, Ph.D.
podpis vedoucí(ho) práce

doc. Ing. Radoslav Bortel, Ph.D.
podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Diplomantka bere na vědomí, že je povinna vypracovat diplomovou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací.
Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v diplomové práci.

Datum převzetí zadání

Podpis studentky

Prohlášení

Prohlašuji, že jsem předloženou práci vypracovala samostatně a že jsem uvedla veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

Dne.....

Abstract

This work explores the possible use of inertial sensors in diagnosing patients with Multiple Sclerosis (MS). The work aims to find effective parameters of signals from inertial sensors and suitable classification methods for distinguishing tremor in patients with MS from physiological tremor in healthy individuals. Measurements were performed using an accelerometer and a gyroscope placed sequentially on both upper limbs with eyes closed and eyes open. Signal processing and analysis of individual methods took place in the MATLAB program. K-means, K-nearest neighbors (K-NN), Support vector machines (SVM) and Naive Bayes classifier algorithms were used for classification. All methods were tested on a group of volunteers consisting of 16 patients suffering from MS and 18 healthy individuals. 5-fold cross-validation was used to evaluate the classification. The classification accuracy of up to 91 % was achieved by the SVM algorithm with a pair of parameters consisting of the Power spectral density (PSD) at a frequency of 7 Hz from measurement of the right hand with eyes closed with a cumulative value of PSD in a fixed band of 0-4 Hz from measurement of the left hand with eyes open. The same accuracy was achieved by the Naive Bayes classifier with parameter values of the signal range from measurement of the left hand with eyes open and PSD at a frequency of 7 Hz from measurement of the right hand with eyes closed. In both cases, these were parameters obtained from gyroscope signals. The K-NN and K-means algorithms achieved lower accuracies. Furthermore, gyroscope data was found to provide better tremor classification results than accelerometer data.

Keywords Multiple Sclerosis, tremor, accelerometer, gyroscope, K-means, K-NN, SVM, Naive Bayes

Abstrakt

Práce se zabývá možným využitím inerciálních senzorů v oblasti diagnostiky pacientů s Roztroušenou sklerózou (RS). Cílem práce je nalezení efektivních parametrů signálů z inerciálních senzorů a vhodných klasifikačních metod pro rozlišení tremoru u pacientů s RS a fyziologického tremoru u zdravých jedinců. Měření probíhala pomocí akcelerometru a gyroskopu umístěných postupně na obou horních končetinách se zavřenýma a otevřenýma očima. Zpracování signálů a analýza jednotlivých metod proběhla v programu MATLAB. Ke klasifikaci byly použity algoritmy K-means, K-nejbližších sousedů (K-NN), Support vector machines (SVM) a naivní Bayesův klasifikátor. Všechny metody byly testovány na skupině dobrovolníků složené z 16 pacientů trpících RS a 18 zdravých jedinců. K výhodnocení klasifikace byla použita 5-fold křížová validace. Celkové přesnosti klasifikace až 91 % dosáhl algoritmus SVM s dvojicí parametrů složené z výkonové spektrální hustoty (PSD) v hodnotě frekvence 7 Hz z měření pravé ruky se zavřenýma očima s kumulativní hodnotou PSD ve fixním pásmu 0-4 Hz z měření levé ruky s otevřenýma očima. Stejné přesnosti dosáhl i naivní Bayesův klasifikátor s hodnotami parametrů rozsahu signálu z měření levé ruky s otevřenýma očima a PSD v hodnotě frekvence 7 Hz z měření pravé ruky se zavřenýma očima. V obou případech se jednalo o parametry získané ze signálů gyroskopu. Algoritmy K-NN a K-means dosahovaly nižších přesností. Dále bylo zjištěno, že data gyroskopu poskytují při klasifikaci tremoru lepší výsledky než data akcelerometru.

Klíčová slova Roztroušená skleróza, tremor, akcelerometr, gyroskop, K-means, K-NN, SVM, naivní Bayes

Seznam použitých zkratek

RS Roztroušená skleróza

CNS Centrální nervová soustava

EBV Vir Epstein-Barrové

RRMS Relaps-reminentní roztroušená skleróza

SPMS Sekundárně progresivní roztroušená skleróza

PPMS Primárně progresivní roztroušená skleróza

ET Esenciální tremor

SVM Support vector machines

K-NN K-nejbližších sousedů (*K-nearest neighbors*)

FTM Fahn-Tolosa-Marin hodnotící škála třesu

RMS Střední kvadratická hodnota

P-P Rozsah (*Peak to peak*)

PSD Výkonová spektrální hustota (*Power spectral density*)

VAS Vizuální analogová škála (*Visual-Analogue Scale*)

NHPT Devítkolíkový test (*Nine-Hole Peg Test*)

CRT Test rotace mince (*Coin rotation test*)

CF Činitel výkyvu (*Crest factor*)

ApEn Aproximační entropie (*Approximation entropy*)

CD Korelační dimenze (*Correlation dimension*)

ACC Přesnost klasifikace (*Accuracy*)

SEN Senzitivita

SPE Specificita

Obsah

1	Úvod	1
2	Teoretický úvod	2
2.1	Roztroušená skleróza	2
2.1.1	Průběh	2
2.1.2	Etiopatogeneze	3
2.1.3	Příznaky	3
2.2	Tremor	4
2.2.1	Dělení podle aktivačních podmínek	4
2.2.2	Kvantifikace a rozložení tremoru	5
2.2.3	Klinické formy	5
2.2.4	Tremor u pacientů s RS	6
2.2.5	Vyšetření tremoru inerciálními senzory	6
2.3	Související práce	6
3	Použité metody	8
3.1	Metodika studie	8
3.1.1	Design studie	8
3.1.2	Průběh vyšetření	8
3.1.3	Anamnéza	9
3.1.4	Klinické testy funkce horních končetin	9
3.1.5	Vyšetření pomocí inerciálních senzorů	10
3.2	Předzpracování dat	11
3.2.1	Filtrace	12
3.2.2	Standardizace dat	12
3.3	Statistické testování	13
3.3.1	Ověření typu rozložení dat	13
3.3.2	Porovnávání kvantitativní veličiny	14
3.4	Klasifikační algoritmy	15
3.4.1	K-means	15
3.4.2	K-NN	16
3.4.3	SVM	17
3.4.4	Naivní Bayesův klasifikátor	17
3.4.5	Hodnocení kvality klasifikace	18
4	Klasifikace tremoru	19
4.1	Použité parametry	19
4.2	Výsledky statistických testů	20
4.3	Výsledky klasifikací dvojic parametrů	21

4.3.1	K-means	21
4.3.2	K-NN	24
4.3.3	SVM	25
4.3.4	Naivní Bayesův klasifikátor	27
4.4	Výsledky klasifikací trojic parametrů	29
4.4.1	SVM	29
4.4.2	Naivní Bayesův klasifikátor	31
4.5	Studie rozšíření použitých klasifikačních metod	32
4.5.1	Rozhodování na principu hlasování SVM klasifikátorů	32
4.5.2	Zařazení třetí třídy pro naivní Bayesův klasifikátor	33
5	Diskuze	35
5.1	Klasifikace dvojic parametrů	35
5.2	Klasifikace trojic parametrů	37
5.3	Možnosti rozšíření použitých metod	37
6	Závěr	39
Reference		41
A Souhlas Etické komise Fakultní nemocnice Královské Vinohrady		44
B Informovaný souhlas účastníka studie		47
C Obsah přiloženého CD		50
D Statistický popis parametrů		51
E Výsledky testu normality		52
F Statisticky významné parametry		53
G Prvních pět klasifikačních dvojic parametrů s nejlepšími výsledky		54
H Hodnocení klasifikací trojic vytvořených ze tří nejčetnějších parametrů prvních 15 dvojic dané klasifikační metody		57

Kapitola 1

Úvod

Roztroušená skleróza (RS) patří v dnešní době mezi nejčastější příčinu progresivní neurologické disability. Její podstatou je autoimunitní zánět, který útočí na myelin obalující nervové dráhy a také na samotná nervová vlákna. Pokud nervová vlákna nedokáží správně vést vztuch nebo dojde k jejich úplné ztrátě, může u pacienta dojít k trvalé invaliditě. Nemoc se v současné době řadí mezi nevyléčitelné, nicméně lze potlačit její projevy pomocí vhodné medikace, pokud je diagnóza stanovena včas.

Jedním z projevů nemoci je mozečkový třes, který postihuje převážně horní končetiny a může zásadně ovlivnit kvalitu života pacienta. Tento třes lze měřit pomocí inerciálních senzorů umístěných na konci ukazováku, které zaznamenávají zrychlení a úhlovou rychlosť objektu ve třech osách. Pro vyšetření funkce horní končetiny se dále používají různé klinické testy jako jsou devítkolíkový test nebo test rotace mince.

Tato práce se zabývá využitím inerciálních senzorů k měření a klasifikaci tremoru u pacientů s RS a zdravých jedinců. Hlavním cílem práce je najít efektivní parametry signálů snímaných akcelerometrem a gyroskopem společně s klasifikační metodou, která bude vhodná pro rozlišení mezi tremorem u pacientů s RS a fyziologickým tremorem u zdravých jedinců. Mezi zkoumané klasifikační algoritmy patří Support vector machines (SVM), K-nejbližších sousedů (K-NN), K-means a naivní Bayesův klasifikátor. Dalším cílem práce je zjistit, zda jsou k této klasifikační úloze vhodnější data z akcelerometru, nebo z gyroskopu.

V současné době je včasná diagnostika RS složitá z důvodu široké škály jejích symptomů, které jsou často přítomny u jiných neurologických onemocnění, společně s nedostatkem specifických neinvazivních diagnostických testů, které by dokázaly jednoznačně potvrdit přítomnost tohoto onemocnění. Identifikace a klasifikace tremoru u pacientů trpících RS představuje důležitý krok v diagnostickém procesu a monitorování progrese onemocnění. V této práci je představeno několik metod, které by mohly do budoucna přispět k vytvoření efektivnějších nástrojů pro diagnostiku této nemoci.

Kapitola 2

Teoretický úvod

První dvě části této kapitoly obsahují teoretický základ problematiky této práce. V první části 2.1 je popsán průběh, příčiny vzniku a příznaky roztroušené sklerózy. V té druhé 2.2 jsou uvedeny základní znalosti o tremoru, jaké jsou druhy, jak lze tremor kvantifikovat, jeho jednotlivé klinické formy, jaký má průběh u pacientů s roztroušenou sklerózou a jak lze tremor vyšetřit pomocí inerciálních senzorů. V poslední části 2.3 je shrnutých několik prací, které se zabývaly stejnou problematikou, a jak k ní přistoupily.

2.1 Roztroušená skleróza

Roztroušená skleróza (RS) patří v dnešní době mezi nejčastější příčiny progresivní neurologické disability. Patogenický mechanismus RS zahrnuje jak autoimunitní tak degenerativní procesy [1]. V případě RS je autoimunitní zánět zodpovědný za napadení myelinu obalujícího nervové dráhy centrální nervové soustavy (CNS). Zánět může napadat samotná nervová vlákna, kdy po jejich úplné ztrátě dochází k trvalé invaliditě [2].

V současné době je RS chronické a nevyléčitelné onemocnění, kterým trpí okolo 3 milionu lidí [1]. Nemoc je diagnostikována nejčastěji mezi 20. a 40. rokem života. Častěji se objevuje u žen a u indoevropského obyvatelstva. S výskytem onemocnění v příbuzenstvu se zvyšuje prevalence až o 3-4 %. Mimo genetické vlivy patří mezi rizikové faktory infekce virem Epstein-Barrové (EBV), kouření, obezita a nedostatek vitamínu D [2].

Diagnostika a léčba RS se v posledních letech zpřesnila a zlepšila. Léčba akutních atak, které toto onemocnění provázejí, a dlouhodobá léčba oddalující invaliditu pomáhají pacientům prodloužit jejich život [2].

2.1.1 Průběh

RS je heterogenní onemocnění, to znamená, že někteří pacienti trpíci touto nemocí jsou ovlivněni minimálně nebo vůbec, zatímco jiní pacienti jsou velmi oslabení. Neurologické symptomy způsobené demyelinizací nervových vláken jsou různé. Patří mezi ně například zhoršení zraku, nekoordinace, mravenčení v končetinách, nerovnováha, porucha chůze, únava a kognitivní dysfunkce. U Většiny pacientů (85-90 %) je RS charakterizována obdobími akutních neurologických poruch (relapsů) [3]. Obvykle relapsy přetrvávají minimálně 24 hodin a nelze je přičíst jiným příčinám jako je infekce nebo změna teploty. Pacienti se poté dělí do skupin podle jejich klinického průběhu [4].

Jedním z nejběžnějších typů RS je relaps-reminentní (RRMS), která sestává z relapsů oddělených různě dlouhými obdobími, kdy jsou projevy nemoci potlačeny. Chronické symptomy mohou přetrvávat nebo se mohou přechodně znova objevit se zvýšenou tělesnou teplotou během infekce nebo intenzivního cvičení jako důsledek oslabeného přenosu signálů

přes demyelinizovaná nervová vlákna. Nemoc je po diagnóze nejvíce aktivní v prvních deseti letích u mladých dospělých. S přibývajícím věkem zánět postupně ustupuje, ačkoliv se mohou stále vyskytovat relapsy ve věku 60 nebo 70 let. Pacienti jsou obvykle sledováni pravidelnými neurologickými vyšetřeními [3].

Přibližně u 75 % pacientů trpících RRMS přechází nemoc na sekundárně progresivní RS (SPMS). Zde dochází k postupnému zhoršení po počátečním relaps-remitujícím průběhu s nebo bez objevu nových relapsů, které se mohou připojit k těm původním [3]. Progrese onemocnění z RRMS do SPMS stádia se obvykle zaznamenává retrospektivně [4].

U zhruba 10-15 % pacientů se zpočátku relapsy nevyskytují, ale jejich postižení se postupně zhoršuje. Často se jedná o postižení motoriky páteře. Tento typ RS se označuje jako primárně progresivní RS (PPMS) a má obvykle pozdější nástup než RRMS [4]. Pokud je nemoc stále doprovázena relapsy, je k nemoci přidáno označení „aktivní“. Vzhledem k tomu, že progresivní onemocnění nepostupuje vždy rovnoměrně, mohou někteří pacienti zůstat po určitou dobu relativně stabilní. Pokud v progresivním průběhu dojde k jednomu či více atakům, označuje se za „PP-aktivní“ [3].

Diagnóza RS je stanovena na základě mezinárodních diagnostických kritérií dle McDonalda z roku 2017. Pacient musí mít typický klinický průběh společně s nálezem hyperintenzních lézí, které odpovídají postižené demyelinizované tkáni, na magnetické rezonanci. K potvrzení diagnózy poté slouží imunologická analýza mozkomíšního moku, která zároveň vyloučí jiné možné příčiny vzniku klinických obtíží [5].

2.1.2 Etiopatogeneze

RS postihuje 2-3x častěji ženy než muže a začíná mezi 20. až 40. rokem života. Řadí se mezi nejčastější příčinu invalidity způsobené neurologickým onemocněním u mladých osob. V České republice trpí tímto onemocněním přibližně 100 tisíc pacientů z toho 10-13 tisíc obyvatel vyžaduje dlouhodobě specializovanou lékařskou péči [6].

Přesná příčina není stále známá, nicméně je více patrné, že nemoc způsobuje kombinace genetických vloh spolu s vlivy zevního prostředí. Mezi genetické predispozice patří určité nastavení imunitního systému a schopnost reagovat autoregresivně na určité podněty. Genové pozadí pacienta je zodpovědné za průběh jeho nemoci, který se u jednotlivých pacientů liší.

Za vlivné vnější faktory se považují různé infekce, mezi které patří zejména EBV a herpatický vir HHV6. Dále mezi tyto faktory řadíme kouření a nedostatek vitaminu D [6]. Mezi nově zjištěné rizikové vnější faktory patří i obezita [2].

2.1.3 Příznaky

Nemoc nese název od rozesetých center autoimunitních zánětu v CNS. Protože jsou některé oblasti zasaženy záněty častěji než jiné, je zde možné nalézt příznaky RS. Podle toho, v jakém místě se ložisko zánětu nachází, se rozhoduje o typu klinických příznaků. Ložiska zánětů se tvoří nejen v bílé, ale i v šedé hmotě CNS, kde je méně myelinizovaných nervových drah [2].

Mezi typické první příznaky onemocnění patří zánět očního nervu neboli optická neuritida. Často se projevuje poklesem zrakové ostrosti na jednom oku, mlhavým viděním nebo těžkou poruchou vize [5]. Pacient se s poruchou zraku již probudí a postupně se zhoršuje.

Dále při neuritidě dochází k bolesti za okem vyvolané jeho pohybem. Těžká optická neuritida s úplnou ztrátou zraku nepatří mezi příznaky RS [7].

Senzitivní příznaky také patří mezi jedny z prvních a rozvíjí se v průběhu hodin až dnů. Může docházet k výpadkům citlivosti nebo pacient pocítí nepříjemné pálení či brnění. Pokud se postižení nachází v místě míchy, dochází poté k poruše čítí na trupu a dolních končetinách. Tyto projevy bývají často přehlíženy [5].

Motorické příznaky mohou být zachyceny včas, neboť zde dochází k viditelnému deficitu hybnosti. Často u pacientů dochází k problémům s chůzí po schodech, zakopávání či zhoršení jemné motoriky [7]. Pokud dojde k poruše okohybné inervace, může následně pacient trpět nechutenstvím, nuceným držením hlavy, nebo může docházet k intenzivní šlehaté bolesti vyvolané pouze malým doteckem [5].

Jedny z posledních a velmi závažných příznaků jsou postižení mozečkových funkcí. Vyznačují se poruchou koordinace končetin, „opileckou“ chůzí, tendencí ztráct rytmus chůze, kdy může nakonec dojít i k pádu. Dále se tento příznak u pacientů objevuje ve formě obtěžujícího a limitujícího třesu končetin (tremoru), který se zpočátku může jevit jako pouhá nešikovnost, kdy například pacientovi vypadávají předměty z rukou [7].

2.2 Tremor

Třes neboli tremor je mimovolní rytmický oscilační pohyb. Pro jednoznačné odlišení tremoru od jiných abnormálních pohybů musí jeho charakteristika splňovat mimovolní vznik, pravidelný rytmus a oscilační ráz. Patří mezi nejběžnější chorobné příznaky a projevy a je součástí řady klinických syndromů. Za jistých okolností se objevuje i u zdravého člověka, proto jeho správná diagnostika patří mezi základní klinické dovednosti [8].

2.2.1 Dělení podle aktivačních podmínek

Tremor lze dělit podle podmínek, které vyvolají jeho vznik, na klidový a akční. Klidový tremor se objevuje na částech těla, které jsou v klidové poloze s plně uvolněnými svaly podepřenými proti působení gravitace. Oproti tomu akční tremor je vyvolán cílenou aktivitou svalu a dále jej dělíme na posturální, kinetický a izometrický [9]. Posturální tremor vzniká při držení části těla v určité poloze nebo nezávisle na ní. Jednoduchý kinetický tremor se objevuje při volném pohybu, který nemá charakter cíleného pohybu. Mezi kinetický tremor se dále řadí tremor intenční a specifický. Intenční tremor vzniká při cíleném pohybu a jeho amplituda postupně s končícím pohybem stoupá. Specifický se objevuje u daných činností jako je na příklad psaní. Mezi poslední druhy tremoru řadíme izometrický, který vzniká spolu s jinými typy tremoru a jeví se jako silná svalové kontrakce [10]. V tabulce 2.1 je přehledněji vypsáno dělení tremoru podle jeho aktivačních podmínek.

Tabulka 2.1: Dělení tremoru podle aktivačních podmínek.

klidový			
akční	- posturální	- závislý na poloze	- nezávislý na poloze
	- kineticky	- jednoduchý	- intenční
		- specifický	
	- izometrický		

2.2.2 Kvantifikace a rozložení tremoru

Frekvenci tremoru lze řadit do tří skupin, a to nízká frekvence (<4 Hz), střední (4-7 Hz) a vysoká (>7 Hz) [11]. Akční tremor celé ruky u některých pacientů trpících RS se může nacházet okolo 2-3 Hz. Unavené svaly nohy po výkonu se chvějí o frekvenci zhruba 6 Hz [12]. Frekvence tremoru se může měnit spolu s místem jeho výskytu na těle.

Tremor je fokální, pokud se nachází pouze v jedné oblasti těla, jako je například hlas, hlava nebo končetina. Segmentální tremor postihuje dvě nebo více sousedících částí těla v horní nebo dolní části. Může se jednat o třes hlavy a paží. Hemi-tremor zasahuje pouze jednu stranu těla, zatímco generalizovaný tremor postihuje horní a dolní část těla oboustranně [13].

2.2.3 Klinické formy

Pro stanovení správné diagnózy pacienta je důležitá znalost přesného popisu jednotlivých klinických projevů třesu. Příznaky se mohou objevovat jak izolovaně jako jediný provoz nemoci, tak kombinovaně, kdy je třes provázen dalšími příznaky. Časem se může počáteční klasifikace měnit [8].

Fyziologický tremor je přítomen v každém svalu, který je schopen samovolně oscilovat. Může být viditelný jako jemné chvění prstu ruky. Amplituda fyziologického tremoru je nízká a jeho frekvence je vysoká u rukou a prstů [11].

Esenciální tremor (ET) patří mezi nejběžnější syndromy chronického třesu o frekvenci 4-10 Hz [10]. Jedná se o izolovaný třesový syndrom obou horních končetin, který trvá minimálně tři roky. V průběhu může být přítomen třes dalších částí těla, ale nejsou zde žádné další neurologické příznaky. ET je často dědičný [13].

K diagnostice mozeckového třesu musí být přítomen dominantní třes jedné nebo obou horních končetin, typicky se jedná o třes intenční. Jeho frekvence bývá pod 5 Hz a zároveň může být přítomen posturální třes, ale žádný klidový. Pokud je akční tremor závažný, může se objevit i tremor klidový, protože se pacient není schopen úplně uvolnit [11].

Parkinsonův třes [8] se vyznačuje jednostranným klidovým třesem ruky o frekvenci 4-6 Hz, který při aktivitě ustupuje. Při delším trvání se tremor objevuje oboustranně se zvýšením amplitudy pouze na jedné straně. Vzácně se při onemocnění může vyskytnout třes dolní čelisti či rtů.

Mimo tyto formy se můžeme dále setkat například s dystonickým, polékovým, psychogenním nebo Holmesovým tremorem [10].

2.2.4 Tremor u pacientů s RS

Předpokládá se, že tremor se vyskytuje až u 75 % pacientů trpících RS [14]. Jeho přesná prevalence však zůstává neznámá, protože funkční škály používané k hodnocení pacientů s RS nehodnotí třes. Různé experimentální studie a klinická pozorování zdůraznily potenciální roli mozečku při produkci třesu s RS.

Dvě novější studie [15] a [16] hodnotily prevalenci třesu u pacientů trpících RS. Studie [15] zkoumala 100 náhodně vybraných pacientů z londýnské kliniky pro léčbu RS a zjistila tremor u 58 % pacientů. Dále zjistili, že tremor ovlivnil především ruce, nohy, hlavu a trup, ale v žádném z případů neovlivnil jazyk, obličej nebo čelist. Druhá studie [16] hodnotila tremor u 200 pacientů trpících RS. Tremor byl nalezen u 25 % pacientů a silný tremor u 3 %.

U pacientů trpících RS se nejčastěji vyskytuje posturální a intenční tremor, které jsou blíže popsány v podsekci 2.2.1. Vzhledem k tomu, že se jedná o multifokální onemocnění, tedy má více ložisek zánětů, nelze výskyt třesu snadno spojit s jedním neuroanatomickým místem. Skutečnost, že u pacientů převažuje akční tremor, značí, že jejich zdrojem je nejpravděpodobněji mozeček, který je zodpovědný za kontrolu pohybové aktivity a svalový tonus. Také běžný výskyt třesu obou končetin ukazuje na poškození mozečku [17].

2.2.5 Vyšetření tremoru inerciálními senzory

Akcelerometry, které měří zrychlení pohybu, a gyroskopy měřící rotaci jsou inerciální senzory, které mohou sloužit k charakterizování tremoru. Používají se ke zjištění frekvence a amplitudy tremoru ve fyzikálních jednotkách translace (cm) a rotace (stupně), které jsou lépe interpretovatelné. Studie [18] ukázala, že použitím inerciálních senzorů lze kvantifikovat tremor u pacientů s ET. Z jejich klinické validace výsledků vyplynulo, že silně korelují s výsledky stupnice hodnocení tremoru. Dále jejich práce ukázala, že tremor lze pomocí senzorů kvantifikovat i za přítomnosti jiných aktivit, a do budoucna by se tento přístup dal použít k domácímu pozorování.

Akcelerometry jsou více používány ke zkoumání tremoru, nicméně měří lineární zrychlení, na rozdíl od lidského pohybu, který je považován spíše za rotaci okolo kloubů. Při měření zrychlení translace jsou zároveň zahrnuty i účinky gravitace. Oproti tomu gyroskopy měří úhlovou rychlosť, a proto poskytují přímější zobrazení lidského pohybu. Dochází u nich ale k nízkofrekvenčnímu zkreslení, které však nijak neovlivňuje odhad třesu. Problém nastává u přesné extrakce úhlů kloubů během delších časových úseků, u kterých je poté přítomen integrační drift [19].

Objektivní kvantifikace tremoru často využívá výkonové spektrální analýzy tremorových průběhů. Frekvenční obsah slouží k rozlišení volního pohybu od pohybu způsobeného patologickým třesem. Volní pohyb odpovídá frekvencím nižším než 3 Hz, zatímco patologický bývá vyšší než 4 Hz. Určité frekvenční oblasti a jejich vrcholové hodnoty jsou poté použity k rozhodnutí mezi různými typy patologického třesu [20].

2.3 Související práce

Pilotní studie [21] měla za cíl kvantifikovat závažnost tremoru u pacientů trpících Parkinsonovou nemocí pomocí signálů získaných z inerciálních senzorů. Byly vypočítány různé parametry jak z časové, tak z frekvenční oblasti ze signálů akcelerometrů a gyroskopů, které

byly umístěny na ukazováku a zápěstí. K posouzení klidového a posturálního třesu využili algoritmus Support vector machines (SVM) s lineárním jádrem. Analýza tohoto přístupu ukázala, že signály ze senzorů na ukazováčku přesněji předpovídají závažnost tremoru. Přesnost jejich klasifikačních modelů dosáhla až 88,9 %.

Výzkum [22] navrhl objektivní hodnocení třesu u pacientů s Parkinsonovou nemocí za použití tříosých inerciálních senzorů. Pohyby pacientů byly zaznamenány prostřednictvím náramku AWEAR umístěným na horní končetině. Opět byly ze signálů extrahovány časové a spektrální parametry, které sloužily následně jako vstup do klasifikačních metod. Mezi tyto parametry patřila na příklad maximální hodnota PSD, kumulativní PSD, přibližná entropie a korelační dimenze. Při klasifikaci pomocí neuronových sítí bylo 34 jedinců ze 40 zařazeno do správných tříd. Přístup s klasifikací k-nejbližších sousedů, neboli K-nearest neighbors (K-NN), klasifikovalo s přesností 91,7 %.

Práce [23] navrhuje multimodální snímání s využitím nositelného zařízení obsahujícího inerciální senzory, které slouží k odhadu skóre na škále hodnocení třesu Fahn-Tolosa-Marin (FTM) a k určení přesnosti klasifikace v rámci typu třesu. Tato práce je zaměřena na měření závažnosti ET. Účastníci kreslili Archimédovu spirálu, zatímco na sobě měli inerciální měřící jednotku umístěnou mezi zápěstím a loktem. Následně byly ze záznamů akcelerometru a gyroskopu vypočítány poměr spektrální hustoty výkonu (PSD) mezi frekvenčními pásmi 0,5-4 Hz a 4-12 Hz a součet PSD po celém spektru 2-74 Hz. Za použití kombinace parametrů z akcelerometru a gyroskopu vyšla přesnost klasifikace SVM modelu 91,42 %.

Studie [24] zkoumá variabilitu vzoru akcelerace trupu u lidí s RS ve srovnání s kontrolní skupinou zdravých jedinců. Z akcelerometrů umístěných na trupu pacientů extrahovali lineární a nelineární míry variability chůze jako jsou střední kvadratická hodnota (RMS), průměrné zrychlení, frekvenční rozptyl, Lyapunovovův exponent a přibližná entropie. U pacientů s RS byl zaznamenán vyšší Lyapunovovův exponent, frekvenční rozptyl a průměrná rychlosť ve směru od jedné strany těla ke druhé. Dále byla zjištěna nižší RMS ve směru od přední části těla k zadní. Tyto výsledky naznačují, že osoby trpící RS mají změněnou strukturu variability trupu během chůze ve srovnání s kontrolní skupinou zdravých jedinců.

Kapitola 3

Použité metody

V první části 3.1 této kapitoly bude přiblížena metodika, která byla použita k získání dat ke klasifikaci. Jsou zde popsány skupiny dobrovolníků, průběh vyšetření a jednotlivé použité testy. V následné části 3.2 je popsáno, jak byla data předzpracována a poté v části 3.3 jsou přiblíženy statistické testy, které byly použity na vyhodnocení dat. V poslední části 3.4 jsou popsány samotné klasifikační algoritmy K-means, K-NN, SVM a naivní Bayes, které byly poté použity ke klasifikaci dat.

3.1 Metodika studie

Tato práce vznikla v rámci studie *Vliv fyzioterapeutických facilitačních technik a virtuální reality na funkci horní končetiny u pacientů s roztroušenou sklerózou*.

Studie proběhla se souhlasem Etické komise Fakultní nemocnice Královské vinohrady, viz příloha A. Všichni účastníci byli seznámeni s obsahem studie a dobrovolně podepsali informovaný souhlas, viz příloha B.

3.1.1 Design studie

Studie proběhla na dvou skupinách účastníků. První skupinu tvoří pacienti s jednoznačnou diagnózou RS určenou na základě kritérií McDonald. Skupina se skládala celkem ze 17 osob s průměrným věkem 53 let se směrodatnou odchylkou 10 let. Mužské pohlaví bylo zastoupeno z 18 %. V této práci byla použita data 16 účastníků, protože jeden nepodstoupil měření s akcelerometrem.

Druhá, kontrolní skupina sestávala z jedinců, kteří byli definitivně bez diagnostikovaného neurologického onemocnění, bez úrazu či ortopedické operace během posledních 5 let či jiného úrazu nebo operace narušující lokomoci a motoriku horních končetin. Dále se muselo jednat o netěhotné ženy a jedince bez akutních a chronických bolestí jakékoli etiologie. V této skupině bylo celkem 18 jedinců s věkovým průměrem 53 let se směrodatnou odchylkou 12 let. Muži byli v této skupině zastoupeni z 50 %.

V obou skupinách byli účastníci vybráni bez ohledu na pohlaví. Pacienti s RS byli vybráni i bez ohledu na věk [25].

3.1.2 Průběh vyšetření

Každý účastník studie byl nejprve podrobně obeznámen s jejím obsahem a následně podepsal informovaný souhlas, viz příloha B, kterým stvrdil svou dobrovolnou účast v této studii. Následně byla u každého účastníka nejprve provedena základní anamnéza spolu s doplňujícími

informacemi ohledně jeho zdravotního stavu. U pacientů s RS byly informace ještě doplněny o detailnější údaje o jejich onemocnění.

Všichni účastníci byli následně podrobeni třem klinickým testům zaměřeným na funkci horních končetin, které budou blíže popsány v sekci 3.1.4. Na závěr proběhlo měření třesu pomocí akcelerometru. Celé vyšetření trvalo přibližně 25 minut [25].

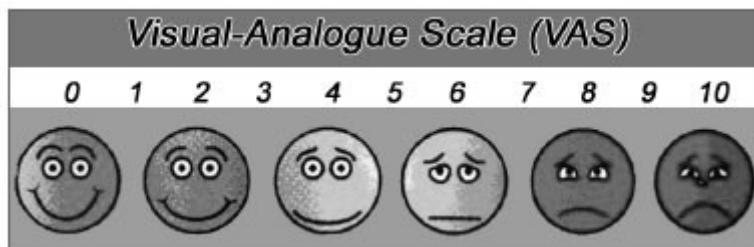
3.1.3 Anamnéza

Všem účastníkům studie byla nejprve provedena základní anamnéza, která zahrnovala informace jako jsou věk, váha, výška a dominance horní končetiny. Všichni účastníci uvedli svou pravou ruku jako dominantní. Mezi anamnézu bylo také zařazeno hodnocení dodatečných otázek ohledně kouření a konzumace alkoholu. Jejich odpovědi byly následně hodnoceny škálou 0-3, kde 0-abstinent/nekuřák, 1-příležitostně, 2-denně, 3-denně ve větším množství (závislost) [25].

U pacientů s RS byla navíc zaznamenána historie jejich onemocnění včetně doby prvních příznaků, typu onemocnění, používání pomůcek při chůzi, používání ortézy, počtu pádů za posledních 6 měsíců a počtu pádů s úrazy. Pro posouzení poruchy chůze u pacientů s RS se používá Hauserův ambulantní index [26]. Tato škála má 10 stupňů a pohybuje se od 0 (žádná porucha chůze) po 9 (omezení vyžadující invalidní vozík). Hodnocení pomocí této škály zahrnuje schopnost chůze a čas potřebný k ujítí přibližně 8 metrů.

Druhé, kontrolní skupině byly položeny otázky cílené na případné zjištění neurologického onemocnění. Osoby s pozitivní neurologickou anamnézou byly z výzkumu vyloučeny [25].

Subjektivní pocit zdraví byl u všech jednotlivců zjištován položením otázky: „Jak se dnes cítíte psychicky/duševně a fyzicky?“, na kterou odpovídali pomocí vizuální analogové škály (VAS) viz obrázek 3.1. Bodové hodnoty VAS se pohybují v rozmezí 0-10, kde 10 značí nejhorší pocit zdraví a 0 nejlepší. V případě rozdílných hodnot subjektivního pocitu psychického a fyzického zdraví byl vypočítán průměr obou hodnot.



Obrázek 3.1: Vizuální analogová škála (VAS) [27] použita k vyhodnocení psychického a fyzického zdraví účastníka studie.

3.1.4 Klinické testy funkce horních končetin

V této studii byly použity tři různé klinické testy pro zjištění funkce horních končetin. Jednalo se o vyšetření síly stisku (Hand grip strength), devítkolíkový test (NHPT) a test rotace mince (CRT).

Vyšetření síly stisku horní končetiny [25] proběhlo pomocí dynamometru od společnosti JAMAR. Účastník seděl na židli tak, aby měl v kyčelních a kolenních kloubech úhel co nejbližší

90°. Paže byly volně u těla v neutrální pozici s loktem v pravém úhlu, předloktí směřující vpřed a zápěstím směřujícím mírně ke straně malíku v rozmezí 0-15° od neutrální pozice. Ruka držící dynamometr byla volně bez podpory vyšetřujícího, kdy dynamometr byl držen vertikálně v prodloužení předloktí. Účastník byl vyzván k maximálnímu stisku dynamometru. Síla stisku byla měřena třikrát na obou horních končetinách. Výsledky pro jednotlivé končetiny byly zprůměrovány a výsledná hodnota síly stisku byla vyjádřena v kilogramech.

NHPT [28] slouží k testování jemné motoriky, koordinace oko - ruka, rychlosti obratnosti horních končetin a schopnosti provádět úkon přesně podle instrukcí. Test tvoří modrá plastová deska s devíti rovnoramenně rozmištěnými otvory a kulatým zásobníkem na devět plastových bílých kolíčků. Kolíčky jsou ve tvaru válce o délce 31 mm a průměru 6 mm. Úkolem probanda je co nejpřesněji a nejrychleji vložit kolíčky po jednom do všech devíti otvorů v desce a následně je opět po jednom vytáhnout a umístit zpět do zásobníku. Rychlosť provedení testu se měří pomocí stopek od okamžiku, kdy se účastník dotkne jednoho z kolíčků, do okamžiku, kdy odloží poslední kolíček do zásobníku. Test byl proveden celkem dvakrát pro každou horní končetinu a výsledný čas byl průměrem hodnot z testů pro danou končetinu.

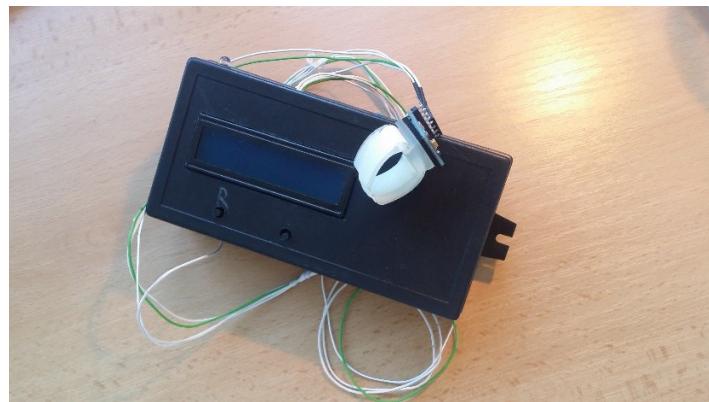
CRT [29] je rychlý a snadno proveditelný test pro měření rychlých a koordinovaných pohybů prstů s mincí. Pro provedení testu museli účastníci co nejrychleji otáčet mincí mezi palcem, ukazovákem a prostředníkem. Úkolem je provést co nejrychleji dvacet půlotáček mince. Čas je opět měřen stopkami. V této studii [25] byl test prováděn s českou pětikorunou. Účastník měl dva pokusy pro každou horní končetinu a výsledný čas byl opět zprůměrován.

V této práci nebyly výsledky z klinických testů horních končetin použity, protože se práce zabývá možností využití dat z inerciálních senzorů ke klasifikaci pacientů s RS.

3.1.5 Vyšetření pomocí inerciálních senzorů

K vyšetření míry tremoru horní končetiny bylo použito zařízení s tříosým akcelerometrem a gyroskopem MotionTracking sensor MPU-6050. Uvedený čip je schopen měřit zrychlení až do ± 16 g (nastaven na ± 2 g) a rotaci až ± 2000 stupňů za vteřinu. Naměřená data byla získána pomocí vlastního zařízení s mikrokontrolérem Atmel Mega 328 a uložena na SD kartu.

Třes byl měřen na prostředníčku pomocí detektoru ve tvaru prstýnku, který lze vidět na obrázku 3.2. Pacient mohl sedět nebo vzpřímeně stát s předpaženou rukou, na které se nacházel senzor třesu. Druhá nevyšetřovaná ruka visela volně podél těla. Vyšetření proběhlo na obou horních končetinách s otevřenýma a zavřenýma očima. V případě měření s otevřenýma očima byl účastník vyzván, aby se díval na jeden stabilní bod přímo před sebe. Od každého pacienta tedy byly naměřeny čtyři různé záznamy o délce minimálně jedné minuty [30].



Obrázek 3.2: Měřící zařízení, které bylo využito k měření třesu u účastníků studie, s detektorem ve tvaru prstýnku obsahujícím tríosý akcelerometr a gyroskop [30].

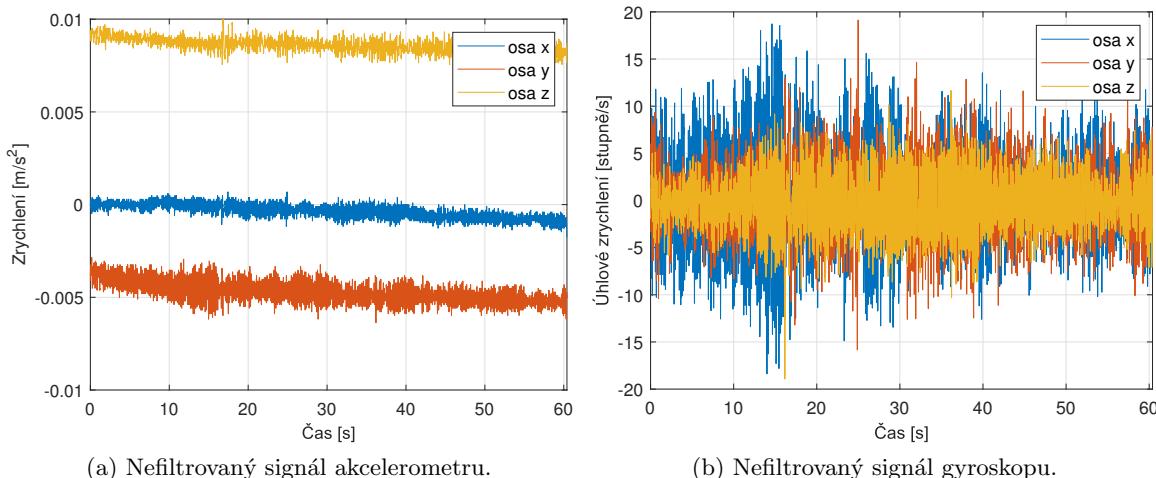
3.2 Předzpracování dat

Akcelerometr a gyroskop měří zrychlení a úhlovou rychlosť ve třech osách se vzorkovací frekvencí 100 Hz. Parametry použité ke klasifikaci byly vypočítány z celkového zrychlení a úhlové rychlosti, které byly získány pomocí vektorového součtu hodnot ze všech tří os. Pro výpočet celkového zrychlení byla použita rovnice

$$A = \sqrt{a_x^2 + a_y^2 + a_z^2}, \quad (3.1)$$

kde hodnoty a_x, a_y, a_z jsou zrychlení v dané ose. Stejný postup byl použit i u signálů z gyroskopu [23].

Na obrázku 3.3 můžeme vidět příklad nefiltrovaných signálů z akcelerometru a gyroskopu náhodně vybrané nahrávky jednoho ze zúčastněných pacientů trpících RS.

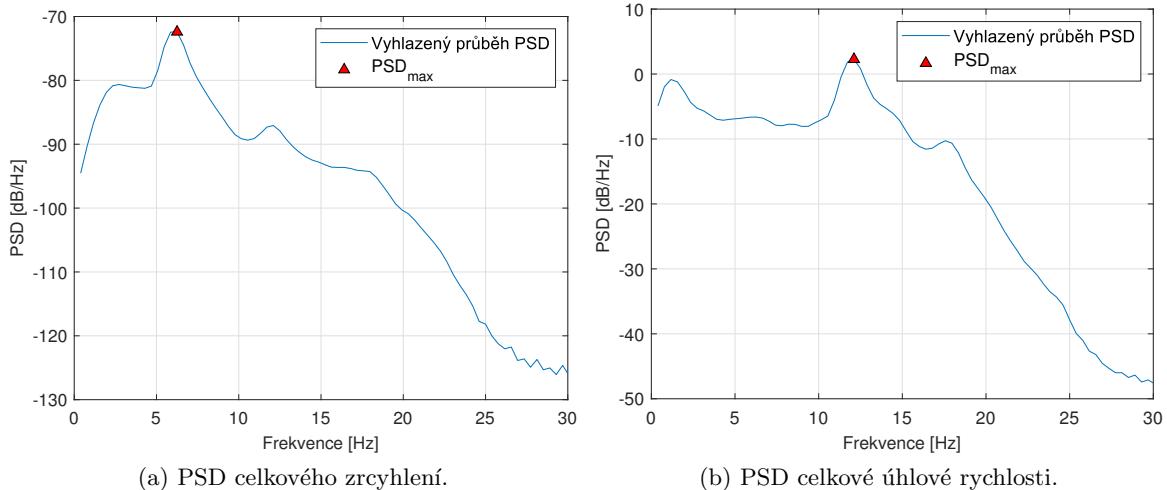


Obrázek 3.3: Na obrázcích (a) a (b) jsou zobrazeny nefiltrované časové průběhy akcelerometru a gyroskopu ve všech třech osách u náhodně vybraného pacienta s onemocněním RS. Pro lepší znázornění jsou zde jednotky zrychlení převedeny z gravitačního zrychlení g na m/s^2 .

3.2.1 Filtrace

Výsledné celkové signály získané výpočtem jejich vektorového součtu byly následně filtrovány pomocí filtru pásmové propusti s mezními kmitočty 0,5 Hz a 20 Hz. Jednalo se o filtr typu Butterworth řádu 4. Spodní mezní kmitočet slouží k odstranění izolinie, zatímco horní kmitočet určuje maximální užitečnou frekvenci 20 Hz, která může projít tímto filtrem s minimálním útlumem.

Z filtrovaného signálu byly vypočteny časové parametry a výkonová spektrální hustota (PSD), která byla následně vyhlazena Hammingovým oknem o délce 128 vzorků. Vyhlazený signál PSD následně také sloužil k výpočtu různých parametrů, které budou dále sloužit ke klasifikaci dat pacientů s roztroušenou sklerózou. Popis jednotlivých parametrů je uveden v podkapitole 4.1. Na obrázku 3.4 jsou vykresleny vyhlazené průběhy PSD signálů akcelerometru a gyroskopu náhodně vybraného pacienta trpícího RS, kde červený trojúhelník značí frekvenci dosahující maximální hodnoty PSD.



Obrázek 3.4: Na obrázcích (a) a (b) lze vidět vyhlazené PSD celkových signálů z akcelerometru a gyroskopu náhodného pacienta s RS. Červený trojúhelník v grafech značí frekvenci s maximální hodnotou PSD.

3.2.2 Standardizace dat

Parametry vypočítané ze signálů akcelerometru a gyroskopu se mohou nacházet v různých dynamických rozsazích. Některé parametry s většími hodnotami by mohly mít větší vliv než parametry jiné, avšak to nemusí nutně odrážet jejich odpovídající význam při návrhu klasifikátoru. Aby se tomuto problému předešlo, byly parametry standardizovány tak, aby jejich hodnoty ležely v podobných rozsazích.

U každého parametru se spočítá nejprve střední hodnota μ jako

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i, \quad (3.2)$$

a směrodatná odchylka σ dle vzorce

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}, \quad (3.3)$$

kde N značí celkový počet hodnot jednoho parametru a x_i značí jednotlivé hodnoty daného parametru. Standardizace každého parametru je provedena se všemi jeho hodnotami, jak ze skupiny pacientů s RS, tak ze skupiny se zdravými kontrolami.

Jednotlivé hodnoty parametrů se přepočítají na standardizované hodnoty pomocí rovnice

$$\tilde{x}_i = \frac{x_i - \mu}{\sigma}. \quad (3.4)$$

Výsledné standardizované parametry mají nulovou střední hodnotu a směrodatnou odchylku rovnu jedné [31].

3.3 Statistické testování

Statistické testování jednotlivých parametrů může sloužit k vyřazení těch parametrů, které nemají statisticky významné rozdíly mezi skupinami pacientů trpících RS a kontrolní skupinou zdravých osob. Parametry, které mají statisticky významné rozdíly mezi skupinami, jsou vhodné pro následnou klasifikaci dat.

3.3.1 Ověření typu rozložení dat

Před samotným hledáním statisticky významných parametrů bylo nejdříve nutné ověřit, zda parametry dané skupiny pocházejí z normálního rozložení. Princip všech testů normality je stejný. Testujeme nulovou hypotézu, která říká, že data pochází z normálního rozložení. Oproti tomu hypotéza alternativní říká, že data pocházejí z rozložení jiného. Po vypočítání testové statistiky se srovnává příslušná p-hodnota se zvolenou hladinou významnosti α . Pokud je p-hodnota nižší než zvolená α , zamítá se nulová hypotéza ve prospěch alternativní.

Pro tuto práci byl zvolen Shapiro-Wilkův test [32], který je vhodný pro menší počet pozorování. Tento test je založen na porovnávání teoretických a empirických kvantilů. Na jeho výsledek W , který je získán výpočtem rovnice

$$W = \frac{\sum_{i=1}^m a_i^{(n)} [X_{(n-i+1)} - X_{(i)}]^2}{\sum_{i=1}^m (X_i - M)^2}, \quad (3.5)$$

lze pohlížet jako na korelační koeficient, který říká, zda data vykazují shodu s normálním rozložením. X_i jsou hodnoty náhodného výběru o počtu n , $m = n/2$ pro sudé n nebo $m = (n-1)/2$ pro liché n a M je výběrový rozptyl vypočítaný pomocí rovnice

$$M = \frac{1}{n} \sum_{i=1}^n X_i. \quad (3.6)$$

3.3.2 Porovnávání kvantitativní veličiny

Ke zjištění, zda lze rozdělit účastníky studie do dvou skupin na základě daného parametru, byly použity testy porovnání kvantitativní veličiny. Z předešlého testu pro ověření typu rozložení dat je známo, zda mají data normální, nebo jiné rozložení.

Pro parametry s normálním rozložením byl použit dvouvýběrový t-test [33], který porovnává střední hodnoty skupin. Pokud je výsledek testu významný, naznačuje vysokou pravděpodobnost, že vzorky reprezentují populace s odlišnými průměrnými hodnotami, tedy mezi skupinami existuje statisticky významný rozdíl. Nulová hypotéza tohoto testu říká, že střední hodnoty skupin se rovnají. Alternativní oproti tomu říká, že se střední hodnoty liší. Statistika t-testu se vypočítá pomocí obecné rovnice

$$t = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\left[\frac{(n_1-1)\tilde{s}_1^2 + (n_2-1)\tilde{s}_2^2}{n_1+n_2-2} \right] \left[\frac{1}{n_1} + \frac{1}{n_2} \right]}}, \quad (3.7)$$

která může být použita pro skupiny se stejným i různým počtem vzorků, a kde \bar{X}_1, \bar{X}_2 jsou střední hodnoty skupin, $\tilde{s}_1^2, \tilde{s}_2^2$ jsou rozptyly daných skupin a n_1, n_2 jsou počty vzorků skupin. Nulová hypotéza se zamítá, pokud je absolutní hodnota t rovna nebo větší než tabulková kritická hodnota.

K porovnání dvou nezávislých vzorků s nenormálním rozložením byl použit Mann-Whitneyův U-test [34]. Tento test spojí oba vzorky do jedné sady dat a následně seřadí vzestupně podle jejich hodnot. Cílem je určit, zda jsou hodnoty z obou vzorků náhodně rozmištěny ve společném pořadí, nebo jestli jsou shlukovány na opačných koncích. Shluk hodnot by znamenal, že je mezi vzorky rozdíl. Vzorec

$$U_i = n_1 n_2 + \frac{n_i(n_i+1)}{2} - \sum R_i \quad (3.8)$$

slouží k určení statistiky Mann-Whitneyova U-testu, kde U_i je výsledná statistika pro vzorek našeho zájmu, n_i je počet hodnot posuzovaného vzorku, n_1, n_2 jsou počty hodnot z prvního a druhého vzorku a $\sum R_i$ označuje součet pořadí vzorků dané skupiny po sloučení všech vzorků do jednoho souboru. Pro zjištění významnosti statistik menších vzorků se používá tabulka s kritickými hodnotami. V případě větších vzorků se vypočítá z-score pomocí rovnice

$$z^* = \frac{U_i - \bar{x}_U}{s_U}, \quad (3.9)$$

kde s_U je směrodatná odchylka a \bar{x}_U střední hodnota, vypočítané pomocí vzorců

$$\bar{x}_U = \frac{n_1 n_2}{2}, \quad (3.10)$$

$$s_U = \sqrt{\frac{n_1 n_2 (n_1 + n_2 + 1)}{12}}. \quad (3.11)$$

Velikost efektu (ES), vypočítaná pomocí rovnice

$$ES = \frac{|z|}{\sqrt{n}}, \quad (3.12)$$

poté slouží k určení míry souvislosti mezi skupinami.

3.4 Klasifikační algoritmy

Ke klasifikaci dat byly zvoleny převážně metody učení s učitelem, přestože pro menší množství vstupních dat jsou vhodnější klasifikátory bez učitele. Předpokládá se, že by tyto metody mohly být v budoucnu používány na větším množství dat, kde mají klasifikátory s učitelem obvykle přesnější a spolehlivější výsledky. Cílem bylo zjistit, jaká z metod bude data nejlépe klasifikovat do dvou tříd, a to „zdravý“ a „nemocný“. Jedním z použitých klasifikátorů je shlukovací algoritmus K-means, který využívá ke zjištění podobnosti mezi body vzdálenost. Následně se poté nabízí klasifikátor K-nejbližších sousedů, který také využívá vzdálenost, ale již se jedná o učení s učitelem, nicméně by mohl mít dobré výsledky i na malých vstupních datech. Dále byl vyzkoušen naivní Bayesův klasifikátor, který je vhodný i pro nízký počet vstupních dat. Nakonec byla zařazena mezi klasifikátory s učitelem i metoda SVM, která se ukázala jako vhodná pro podobné případy klasifikací dat, jaké jsou přiblíženy v sekci 2.3, se souvisejícími pracemi.

3.4.1 K-means

Algoritmus K-means [35] řeší problém identifikace skupin nebo shluků datových bodů v multidimenzionálním prostoru. Jedná se o algoritmus s učením bez učitele, tedy ke svému trénování nepotřebuje znát třídy přiřazené k jednotlivým pozorováním. Hlavním úkolem je rozdělit data do určitého počtu K shluků, jejichž středy jsou označeny jako centroidy. Intuitivně se shluk jeví jako skupinu bodů, jejichž vzájemné vzdálenosti jsou malé ve srovnání se vzdálenostmi k bodům mimo shluk. Algoritmus iterativně hledá hodnoty vektorů, které určují polohu centroidu tak, že minimalizuje součet čtverců vzdáleností mezi zadanou množinou dat a centroidy.

Základní vzdálenost, která se obvykle v rámci algoritmu K-means využívá, a na které je tento algoritmus v této kapitole vysvětlen, je Euklidovská vzdálenost. Vzdálenosti, které byly použity v této práci, jsou popsány níže v této podkapitole. Samotný K-means algoritmus začíná inicializací předem určeného počtu K vektorů na náhodně zvolenou hodnotu nebo pomocí vhodně zvolené heuristiky. V našem případě je $K = 2$, neboť data budou klasifikována do dvou tříd zdravý/nemocný. Poté se iterativně provádí následující kroky:

- (i) *Klasifikace*: Jednotlivá data x_i se přiřadí do tříd y_i určených vektory μ_i podle minima Euklidovské vzdálenosti. To lze zapsat rovnicí

$$y_i = \operatorname{argmin}_j \|x_i - \mu_j\|. \quad (3.13)$$

- (ii) *Přepočítání vektorů*: Nové hodnoty vektorů μ_j se vypočítají jako střední hodnoty dat x_i , které byly klasifikovány do příslušné třídy určené vektorem μ_j , podle vztahu

$$\mu_j = \frac{1}{l_j} \sum_{i=1, y_i=j}^l (x_i), \quad (3.14)$$

kde l_j udává počet bodů, které jsou přiřazeny k j-tému shluku a l je celkový počet dat.

Kroky algoritmu se opakují, dokud dochází ke změně v přiřazení bodů do shluků [36].

Vzdálenost

Vzdálenost neboli metrika [36] definuje jaká je vzdálenost mezi dvěma prvky. Je to jeden z nejběžnějších způsobů, jak vyjádřit podobnostní vztah mezi objekty, odvozený z geometrických modelů dat. Obecně je metrika δ funkce, která přiřadí každé dvojici bodů (r, s) z Euklidovského p -rozměrného prostoru \mathbf{E}_p reálné číslo, které splňuje následující axiomy:

- $\delta(r, s) = 0 \iff r = s$ (identita)
- $\delta(r, s) \geq 0$
- $\delta(r, s) = \delta(s, r)$ (symetrie)
- $\delta(r, s) \leq \delta(r, s) + \delta(s, t)$ (trojúhelníková nerovnost)

Minkowského metrika je definována vztahem

$$\delta(r, s)_k = \sqrt[k]{\sum_{i=1}^p (r_i - s_i)^k}. \quad (3.15)$$

Při použití různých k lze odvodit další metriky:

(i) $k = 1$, Manhattanská vzdálenost

$$\delta(r, s)_1 = \sum_{i=1}^p |r_i - s_i| \quad (3.16)$$

(ii) $k = 2$, Euklidovská vzdálenost

$$\delta(r, s)_2 = \sqrt{\sum_{i=1}^p (r_i - s_i)^2} \quad (3.17)$$

(iii) $k \rightarrow \infty$, Čebyševská vzdálenost

V této práci pro K-means algoritmus byly použity Euklidovská a Manhattanská metrika.

3.4.2 K-NN

Mezi hlavní výhody algoritmu K-nejbližších sousedů (K-NN) [37] patří jeho snadná implementace a odolnost vůči šumovým tréninkovým datům. Protože se jedná o algoritmus učení s učitelem, jeho princip spočívá v určení třídy nového vzorku na základě známých tříd jeho k-nejbližších sousedních vzorků. Nejprve tedy vypočítá vzdálenosti klasifikovaného bodu od všech ostatních bodů v množině, vybere k bodů s nejmenší vzdáleností a následně přiřadí klasifikovanému bodu tu třídu, která má nejčastější zastoupení u k nejbližších bodů. Když se jedná o klasifikaci do dvou tříd, je vhodné zvolit liché k , aby nedocházelo ke stejnému zastoupení obou tříd. Algoritmus opět využívá pro výpočet vzdálenosti mezi vzorky různé metriky, které jsou blíže popsány u algoritmu K-means v části 3.4.1. Mezi nejčastěji používané patří Euklidovská vzdálenost, která měří vzdálenost mezi dvěma body v rovině, a která byla také ve spojení s tímto algoritmem použita.

3.4.3 SVM

Hlavním cílem algoritmu Support vector machines (SVM) [38] je oddělit známé třídy v trénovací sadě dat plochou, která maximalizuje „margin“, což je vzdálenost mezi nejbližším bodem každé třídy a plochou. K transformaci vstupních dat z prostoru X do prostoru vyšší dimenze F , která následně umožňuje lepsí oddelení jednotlivých tříd pomocí lineárního separátoru, používá kernel funkci. Jedná se o matematickou funkci, která měří podobnost mezi dvěma vektory v prostoru dat. Jádro (kernel) je funkce K taková, že pro každé $x, z \in X$ platí

$$K(x, z) = \langle \phi(x) \cdot \phi(z) \rangle, \quad (3.18)$$

kde ϕ je zobrazení z X do prostoru příznaků F . Kernel musí splňovat následující vlastnosti, pro libovolné $x, y, z \in X, a \in \mathbb{R}$:

- $x \cdot x = 0$ pouze tehdy když $x = 0$
- $x \cdot x \geq 0$ v ostatních případech
- $x \cdot y = y \cdot x$
- $(\alpha x \cdot y) = \alpha(x \cdot y)$
- $(z + x) \cdot y = (z \cdot y) + (x \cdot y)$

Pokud jsou data lineárně separovatelná, lze použít rozhodovací pravidlo f s lineárním kernelem

$$f(x) = \sum_{i=1}^l \alpha_i y_i K(x_i \cdot x_j) + b, \quad (3.19)$$

který operuje přímo v původním prostoru dat a jeho funkce spočívá v určení skalárního součinu mezi vektory dat. Rozhodovací pravidlo využívá vah α_i , které jsou reprezentovány Lagrangeovými multiplikátory. Ty jsou přiřazeny trénovacím vzorkům, jejichž třídy jsou y_i , tak aby zajistily nejlepší oddelení mezi dvěma třídami. Body s váhou $\alpha_i \geq 0$ jsou podpůrné vektory. Tyto vektory jsou nejbliže rozhodovací ploše a definují margin, který je dán dvěma hyperrovinama. Váhy reflektují vztahy trénovacích vzorků k novému vstupnímu vzorku a následně pomocí kernel funkce klasifikují vstupní vzorek do jedné ze tří se zkreslením b .

Při řešení problémů, kdy nejsou data dokonale separovatelná, využívá SVM koncept Soft margin. To umožňuje, aby byly některé body špatně klasifikovány s penalizací řízenou určitým parametrem. SVM algoritmus bez použití přístupu Soft margin se nazývá tvrdé SVM.

V této práci byl využit algoritmus s lineární kernel funkcí, neboť zde byl předpoklad lineárně separovatelných dat. Pokud data nejsou lineárně separovatelná, používá se Gaussovské, Polynomiální, RBF nebo Sigmoid jádro, které je vždy dané příslušnou matematickou funkcí.

3.4.4 Naivní Bayesův klasifikátor

Bayesova klasifikace [39] vychází z Bayesovy věty o podmíněných pravděpodobnostech, která je dána vztahem

$$P(y_j | \mathbf{x}_i) = \frac{P(\mathbf{x}_i | y_j) P(y_j)}{P(\mathbf{x}_i)}. \quad (3.20)$$

Tento vztah umožňuje vypočítat podmíněnou pravděpodobnost třídy y_j za přítomnosti pozorování \mathbf{x}_i .

Předpoklad pro využití Naivního Bayesova klasifikátoru je, že jednotlivá pozorování $\mathbf{x}_{1,\dots,n}$ jsou nezávislá při platnosti dané třídy. V reálných úlohách je tento předpoklad málokdy

splněn, proto označení „naivní“. Cílem klasifikátoru je nalézt třídu \hat{y} s největší podmíněnou pravděpodobností pro dané pozorování x_k s p atributy. Hledání nejlepší třídy lze zapsat pomocí rovnice

$$\hat{y} = \operatorname{argmax}_{y_j} \prod_{k=1}^p P(x_k|y_j)P(y_j). \quad (3.21)$$

Apriorní pravděpodobnosti jednotlivých skupin jsou odhadnutý jako podíl vzorků dané skupiny v trénovací množině k celkové velikosti trénovací množiny. Za předpokladu, že data mají normální rozdělení, jsou podmíněné pravděpodobnosti získány na základě modelování pravděpodobnostní hustoty pro každou třídu

$$f(x|y_i) = \frac{1}{\sqrt{2\pi}\sigma_i} e^{-\frac{1}{2}(\frac{x-\mu_i}{\sigma_i})^2}, \quad (3.22)$$

kde μ_i a σ_i označují střední hodnotu a směrodatnou odchylku třídy y_i v trénovací množině dat. Pravděpodobnostní hustota je následně dosazena za podmíněnou pravděpodobnost do původního vzorce (3.20).

3.4.5 Hodnocení kvality klasifikace

K vyhodnocení výkonnosti modelů byla využita křížová validace, v rámci které se data rozdělí na více částí. Jedna část vždy slouží jako testovací data, zatímco zbylé části slouží jako data trénovací. Jedním z typů křížové validace je K-fold křížová validace [40], která rozdělí data do k skupin. K trénování modelu slouží $k - 1$ skupin. Model je následně vyhodnocen na zbývající skupině. Tento postup se opakuje tak, aby každá skupina byla použita jako testovací. V této práci je použita křížová validace s 5 skupinami. Výsledná hodnocení kvality z k modelů je poté zprůměrováno.

K vyhodnocení kvality modelů je vypočítána klasifikační přesnost (ACC - Accuracy) [41] pomocí vzorce

$$ACC = \frac{\text{počet správně klasifikovaných pozorování}}{\text{celkový počet pozorování}}. \quad (3.23)$$

Dále jsou využita hodnotící kritéria specificita (SPE - Specificity) a senzitivita (SEN - Sensitivity) [41] vypočítané pomocí rovnic

$$SPE = \frac{\text{počet skutečně negativních}}{\text{počet skutečně negativních} + \text{počet falešně pozitivních}}, \quad (3.24)$$

$$SEN = \frac{\text{počet skutečně pozitivních}}{\text{počet skutečně pozitivních} + \text{počet skutečně negativních}}. \quad (3.25)$$

Hodnoty senzitivity představují pravděpodobnost, že určitý diagnostický test identifikuje pacienty s danou chorobou, tedy správně identifikuje pozitivní výsledky. Test s vysokou senzitivitou říká, že je vysoká šance zachycení přítomnosti sledovaného stavu u daného pacienta. Specificita testu určuje pravděpodobnost, že test diagnostikuje správně pacienty bez choroby. Čím vyšší je hodnota specificity, tím vyšší je šance, že test správně identifikuje negativní výsledky. Dobrý test má vysoké hodnoty obou těchto kritérií.

Kapitola 4

Klasifikace tremoru

První část 4.1 této kapitoly se zabývá parametry, které jsou použité při klasifikaci. Ve druhé části 4.2 jsou uvedeny výsledky statistických testů, na kterou navazují dvě části 4.3 a 4.4 s výsledky klasifikace. Poslední část 4.5 se zabývá studií rozšíření použitých klasifikačních metod.

Veškerá data byla zpracována pomocí programu MATLAB R2023b. Použitý zdrojový kód je přiložen v digitální podobě. Popis digitálních souborů je v příloze C.

4.1 Použité parametry

Pro klasifikaci do tříd zdravý/nemocný bylo vypočítáno devět různých parametrů pro každý ze čtyř celkových signálů akcelerometru a gyroskopu, které byly získány pomocí rovnice (3.1). Celkem se studie zúčastnilo 35 dobrovolníků, z toho 17 probandů trpělo onemocnění RS a 18 byli zdravý jedinci. U jednoho pacienta s RS neproběhlo měření třesu pomocí akcelerometru a u druhého neproběhl devítkolíkový test a test rotace mince. Pacient bez měření třesu akcelerometrem byl tedy z klasifikace vyřazen. Byla použita data od 16 pacientů s RS a 18 zdravých účastníků, celkem se jednalo o 34 záznamů.

Ze signálů akcelerometru a gyroskopu byly vypočítány parametry jak z frekvenční, tak časové oblasti signálů. Prvním parametrem z frekvenční oblasti byla hodnota frekvence s největším zastoupením v signálu f_{max} , s jednotkou Hz. Dalšími parametry z frekvenční oblasti byly maximální hodnota PSD PSD_{max} a hodnota PSD pro frekvenci 7 Hz PSD_{7Hz} . Oba tyto parametry mají jednotku $\text{dB} \cdot \text{Hz}^{-1}$. Poslední z těchto parametrů byla kumulativní hodnota PSD ve frekvenčním pásmu 0-4 Hz PSD_{0-4Hz} s jednotkou dB. Z časové oblasti byly získány střední kvadratická hodnota RMS (Root mean square) a rozsah $P-P$ (Peak to peak) s jednotkami stejnými jako má daný signál, ze kterého byl parametr vypočítaný, tedy pro akcelerometr se jedná o gravitační zrychlení g a pro gyroskop stupně $\cdot \text{s}^{-1}$. Nakonec byly vypočítány tři bezrozměrné parametry z časové oblasti, a to činitel výkyvu CF (Crest factor), approximační entropie $ApEn$, která udává míru náhodnosti v časové řadě, a korelační dimenze CD , která popisuje složitost struktury časové řady. V tabulce 4.1 je uveden statistický popis parametru PSD_{max} . Jsou zde uvedeny střední hodnoty μ se směrodatnými odchylkami σ pro všechna čtyři měření, která byla provedena na pacientech, a pro data obou senzorů, jak akcelerometru, tak gyroskopu. V příloze D je poté uveden statistický popis všech vypočítaných parametrů.

Protože byly od každého probanda naměřeny čtyři různé signály (zavřené/otevřené oči, pravá/levá horní končetina), bylo pro každého účastníka vypočteno celkem $9 \cdot 4 = 36$ parametrů jak z akcelerometru, tak gyroskopu, celkem tedy 72 parametrů pro jednoho účastníka studie. Parametry vypočítané ze signálů akcelerometru a gyroskopu byly při klasifikaci použity zvlášť.

Tabulka 4.1: Příklad statistického popisu se střední hodnotou μ a směrodatnou odchylkou σ parametru PSD_{max} získaného ze signálů akcelerometru a gyroskopu.

Akcelerometr			
Parametr	Typ měření	Skupina s RS $\mu \pm \sigma$	Kontrolní skupina $\mu \pm \sigma$
PSD_{max} [dB · Hz ⁻¹]	Pravá HK otevřené oči	-37.54 ± 7.02	-43.50 ± 3.32
	Levá HK otevřené oči	-37.68 ± 5.94	-44.18 ± 3.40
	Pravá HK zavřené oči	-37.21 ± 7.40	-43.74 ± 2.64
	Levá HK zavřené oči	-35.81 ± 8.54	-43.16 ± 2.94
Gyroskop			
Parametr	Typ měření	Skupina s RS $\mu \pm \sigma$	Kontrolní skupina $\mu \pm \sigma$
PSD_{max} [dB · Hz ⁻¹]	Pravá HK otevřené oči	1.60 ± 9.82	-6.76 ± 4.52
	Levá HK otevřené oči	3.83 ± 8.80	-7.92 ± 3.23
	Pravá HK zavřené oči	0.82 ± 7.10	-7.78 ± 3.51
	Levá HK zavřené oči	1.49 ± 10.24	-7.46 ± 3.22

4.2 Výsledky statistických testů

Před provedením statistických testů byly všechny parametry standardizovány tak, aby měly střední hodnotu rovnou nule a směrodatnou odchylku rovnu jedné. Přesný postup standardizace dat je popsán v podkapitole 3.2.2. Následně mohlo proběhnout statistické testování složené z ověření, zda mají parametry normální rozložení, a následného zjištění statisticky významných rozdílů mezi skupinami zdravý/nemocný u daného parametru. Podle toho, zda parametry měly, nebo neměly normální rozložení, byl zvolen test pro zjištění rozdílu mezi skupinami. V tabulce 4.2 lze vidět výsledné *p-hodnoty* testu normality pro parametr PSD_{max} . Výsledky testu normality všech parametrů jsou uvedeny v příloze E.

Tabulka 4.2: Výsledné *p-hodnoty* testu ověření rozložení dat parametru PSD_{max} signálu akcelerometru i gyroskopu.

Akcelerometr			
Parametr	Typ měření	Skupina s RS p-hodnota [-]	Kontrolní skupina p-hodnota [-]
PSD_{max}	Pravá HK otevřené oči	0.44	0.001
	Levá HK otevřené oči	0.38	0.01
	Pravá HK zavřené oči	0.06	0.01
	Levá HK zavřené oči	0.12	0.55
Gyroskop			
Parametr	Typ měření	Skupina s RS p-hodnota [-]	Kontrolní skupina p-hodnota [-]
PSD_{max}	Pravá HK otevřené oči	0.23	0.09
	Levá HK otevřené oči	0.38	0.32
	Pravá HK zavřené oči	0.68	0.20
	Levá HK zavřené oči	0.41	0.48

Testy porovnání kvantitativních veličin popsané v podkapitole 3.3 byly využity

k vyřazení parametrů, které mezi skupinami zdravý/nemocný nemají významné statistické rozdíly. S celkovým počtem 36 parametrů od signálů každého senzoru byla zvolena vysoká hladina významnosti $\alpha = 0.01$. Parametry, které měly *p-hodnotu* nižší, něž byla určená hladina významnosti, byly z následné klasifikace vyřazeny. V tabulce 4.1 jsou uvedeny výsledky parametru PSD_{max} signálu akcelerometru, který byl statisticky významný. Jsou zde vidět jak výsledné *p-hodnoty* statistického testu, tak hodnoty *statistiky* daného provedeného testu. Výsledky všech parametrů, které byly statisticky významné a byly použity ke klasifikaci, jsou uvedeny v příloze F. Celkem vyšlo 39 statisticky významných parametrů, z toho 18 jsou parametry získané ze signálů akcelerometru a 21 ze signálů gyroskopu.

Tabulka 4.3: Výsledné *p-hodnoty* a hodnoty *statistiky* daného testu statisticky významných rozdílů mezi skupinami zdravý/nemocný parametru PSD_{max} .

Akcelerometr			
Parametr	Typ měření	p-hodnota [-]	statistika [-]
PSD_{max}	Pravá HK otevřené oči	0.005	361
	Pravá HK zavřené oči	0.002	369
	Levá HK otevřené oči	0.002	369
	Levá HK zavřené oči	0.002	3.43

4.3 Výsledky klasifikací dvojic parametrů

Prvním přístupem ke klasifikaci dat bylo vytvoření klasifikačních dvojic z parametrů, které vyšly jako statisticky významné podle testu porovnání kvantitativní veličiny s hladinou významnosti $\alpha = 0.01$. Dvojice byly vytvořeny zvlášť pro parametry dat z akcelerometru a zvlášť pro parametry dat z gyroskopu. Signály z akcelerometru měly celkem 18 významných parametrů, ze kterých bylo nakombinováno celkem 153 dvojic. Signály z gyroskopu měly celkem 21 významných parametrů, ze kterých následně vzniklo 210 různých dvojic. Klasifikace vždy probíhala zvlášť pro dvojice parametrů dat z akcelerometru a dat z gyroskopu. Všechny přístupy byly vyhodnoceny 5-fold křížovou validací s výpočtem klasifikační přesnosti (ACC), senzitivity (SEN) a specificity (SPE). Ze všech pěti kombinací trénovacích a testovacích dat byla vypočítána hodnotící kritéria klasifikace, ze kterých byla následně určena střední hodnota μ se směrodatnou odchylkou σ , které určovaly výslednou přesnost klasifikace a kvalitu daného klasifikačního modelu. Výsledné hodnoty jsou psané ve tvare $(\mu \pm \sigma)$ %. Přesnější popis vyhodnocení klasifikace je obsažen v podkapitole 3.4.5. U jednotlivých parametrů bylo zavedeno značení s písmeny R/L (pravá/lehá horní končetina) a O/C (otevřené/zavřené oči) podle toho, z jakého ze čtyř měření byl parametr vypočítán. Všichni účastníci měli dominantní pravou ruku. Pokud je tedy parametr vypočítán z měření pravé horní končetiny, jedná se o měření nahrané na dominantní ruce.

Celkové přesnosti s hodnotícími kritérii všech dvojic parametrů jednotlivých použitých klasifikačních metod jsou přiložené v digitální podobě. Popis digitálních souborů s výsledky je obsažen v příloze C.

4.3.1 K-means

Při klasifikaci byly použity dva různé druhy metriky. Použita byla Euklidovská a Manhattanovská vzdálenost, jejichž přesnější definice jsou sepsané v podkapitole 3.4.1. Každá dvo-

jíce byla klasifikovaná dvakrát, jednou pro každý typ metriky, a navíc ještě pětkrát pro různé skupiny trénovacích a testovacích dat vytvořené při křížové validaci.

Z výsledných přesností uvedených v tabulce 4.4 je zřejmé, že klasifikace parametrů gyroskopu vychází přibližně o 3% lépe oproti klasifikaci s parametry dat z akcelerometru. Platí to jak u vzdálenosti Manhattanské, tak Euklidovské. Výsledky klasifikací za využití různých vzdáleností dosahují přibližně stejné přesnosti, nelze tedy v tomto případě říci, že by jedna z těchto vzdáleností klasifikovala data jednoznačně lépe než vzdálenost druhá. U obou použitých vzdáleností má také senzitivita a specificita má vyšší hodnoty pro klasifikace parametrů dat z gyroskopu.

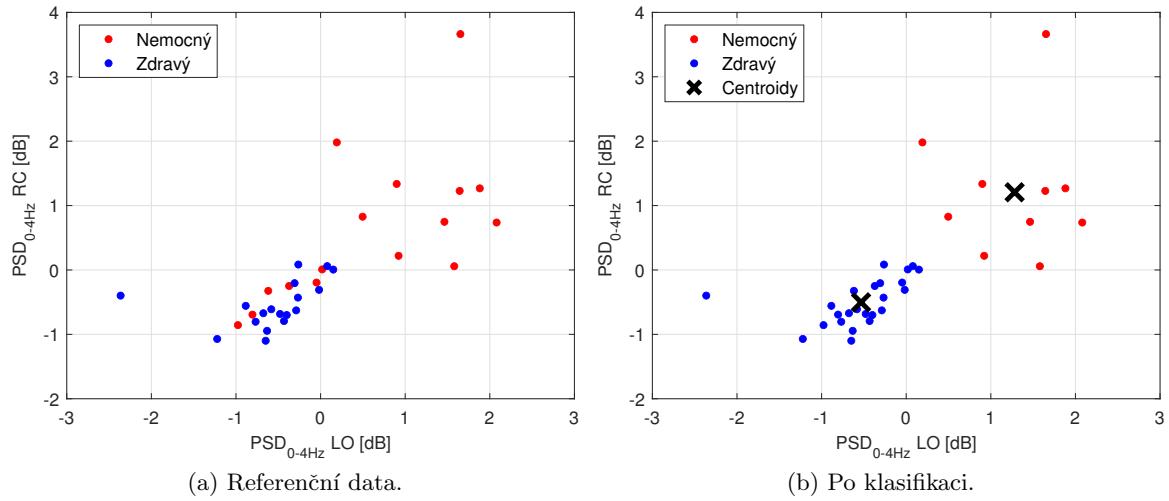
Z provedené K-means klasifikace vykazuje nejvyšší celkovou přesností dvojice parametrů signálů z gyroskopu PSD_{7Hz} z měření pravé horní končetiny se zavřenýma očima s parametrem $ApEn$ z levé pravé horní končetiny s otevřenýma očima za použití Manhattanské vzdálenosti. Tato dvojice dosáhla přesnosti $(85.71 \pm 14.29) \%$. Dvojice parametrů signálů z gyroskopu s nejvyšší přesností při použití Euklidovské vzdálenosti dosáhla téměř stejně celkové přesnosti s nižší směrodatnou odchylkou. V tabulce 4.4 jsou vypsané dvojice parametrů akcelerometru a gyroskopu, které dosahovaly nejvyšší přesnosti při K-means klasifikaci za použití Euklidovské i Manhattanské vzdálenosti. U všech dvojic parametrů je zřejmé, že hodnoty specificity dosahují lepších výsledků oproti hodnotám senzitivity. Prvních pět dvojic s nejvyšší dosaženou celkovou přesností klasifikace je uvedeno v tabulce G.1 v příloze G.

Tabulka 4.4: Výsledná kritéria dvojic parametrů K-means klasifikace s nejvyššími celkovými přesnostmi za využití Euklidovské a Manhattanské vzdálenosti.

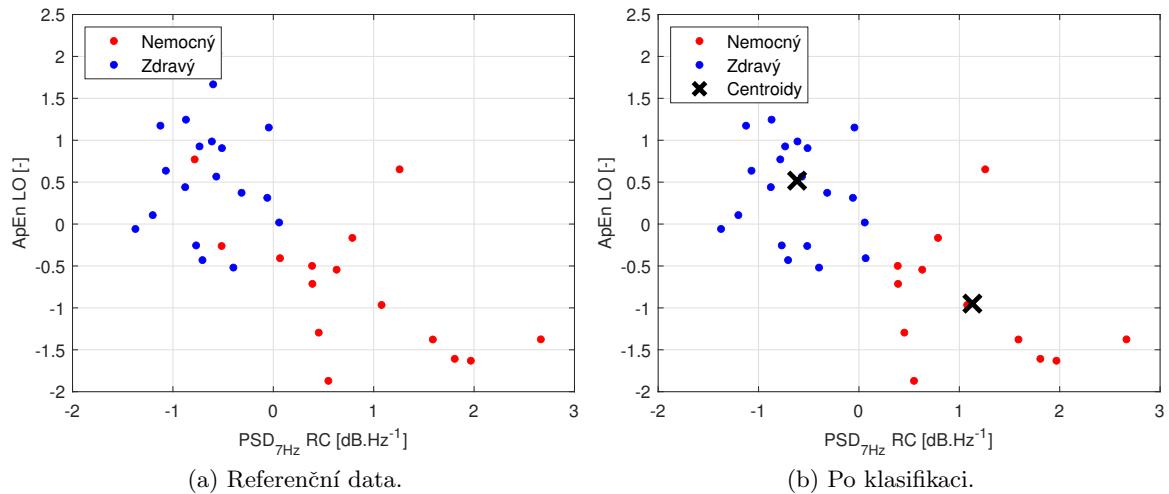
Akcelerometr					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Vzdálenost	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{0-4Hz} LO	PSD_{0-4Hz} RC	Euklidovská	82.38 ± 11.85	68.33 ± 20.75	100 ± 0
PSD_{max} LO	PSD_{0-4Hz} RC	Manhattanská	82.56 ± 11.95	60.95 ± 25.68	80 ± 44.72
Gyroskop					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Vzdálenost	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{7Hz} RC	PSD_{max} LO	Euklidovská	85.24 ± 10.16	70.0 ± 24.01	100 ± 0
PSD_{7Hz} RC	$ApEn$ LO	Manhattanská	85.71 ± 14.29	76.77 ± 32.49	93.33 ± 14.91

Na obrázku 4.1 je zobrazena dvojice parametrů dat z akcelerometru PSD_{0-4Hz} LO s PSD_{0-4Hz} RC před a po klasifikaci K-means s Euklidovskou vzdáleností, která dosáhla nejvyšší přesnosti. Jednotlivé skupiny jsou barevně rozlišené. Můžeme si zde všimnout změny barvy některých bodů, u kterých po klasifikaci došlo k přiřazení do opačné skupiny, než do které původně patří. Tento model byl vytvořen za použití všech dat, která jsou vyhodnocována v rámci této práce. Dvojici parametrů dat z gyroskopu s nejvyšší přesností K-means klasifikace je znázorněna na obrázku 4.2, tentokrát s použitím Manhattanské vzdálenosti. Opět zde můžeme vidět změnu přiřazení bodů před a po klasifikaci jako u předešlého obrázku 4.1. K vytvoření tohoto modelu byla opět použita všechna data.

Celkem 100 dvojic parametrů signálů z akcelerometru u klasifikace s Euklidovskou vzdáleností dosáhlo celkové přesnosti více než 70 %, s Manhattanskou vzdáleností se jednalo o 121 dvojic. U signálů gyroskopu této přesnosti dosáhlo 136 dvojic s Euklidovskou vzdáleností a 163 dvojic se vzdáleností Manhattanskou.



Obrázek 4.1: Znázornění dvojice parametrů akcelerometru s nejvyšší přesností K-means klasifikace s Euklidovskou vzdáleností. Na obrázku (a) můžeme vidět dvojici parametrů se znázorněním jednotlivých skupin zdravý/nemocný před klasifikací a na obrázku (b) je poté vidět jak se změnilo přiřazení bodů do skupin po klasifikaci. Křížky v obrázku (b) znázorňují centroidy skupin.



Obrázek 4.2: Znázornění dvojice parametrů gyroskopu s nejvyšší přesností K-means klasifikace s Manhattanovou vzdáleností. Na obrázku (a) můžeme vidět dvojici parametrů se znázorněním jednotlivých skupin zdravý/nemocný před klasifikací a na obrázku (b) je poté vidět jak se změnilo přiřazení bodů do skupin po klasifikaci. Křížky v obrázku (b) znázorňují centroidy skupin.

4.3.2 K-NN

V případě K-NN klasifikace byla použita pouze Euklidovská vzdálenost se dvěma různými počty nejbližších sousedů, podle kterých se klasifikuje pozorovaný bod. Vzhledem k tomu, že byla data klasifikována do dvou skupin, byl počet nejbližších sousedů zvolen na tři a pět, aby nedocházelo k nerozhodnému přiřazení třídy.

Rozdíl mezi výsledky s použitím tří nebo pěti sousedů nebyl téměř žádný. Minimálně 80 % celkové přesnosti dosahovalo u parametrů akcelerometru 5 dvojic s počtem tří nejbližších sousedů a 3 dvojice s použitím pěti sousedů. U gyroskopu této přesnosti dosahovalo 39 dvojic za použití tří sousedů a 44 dvojic s pěti sousedy. Je zde ale znatelný rozdíl mezi výsledky akcelerometru a gyroskopu. Celkové přesnosti klasifikace s hodnotou minimálně 80 % dosahuje více dvojic parametrů dat z gyroskopu.

Nejlepších výsledků ze všech možností K-NN klasifikace dosahují dvě dvojice parametrů signálů z gyroskopu se stejnou celkovou přesností. První dvojice parametrů je *RMS* z měření pravé ruky se zavřenýma očima s PSD_{0-4Hz} z měření levé ruky se zavřenýma očima. Tato dvojice dosáhla celkové přesnosti klasifikace $(88.57 \pm 11.95) \%$ s využitím tří nejbližších sousedů. Dvojice parametrů u klasifikace s využitím pěti sousedů dosáhla stejně přesnosti. Jednalo se o parametry *RMS* z měření levé ruky s otevřenýma očima společně s *P-P* z měření pravé ruky se zavřenýma očima. Všechny střední hodnoty se směrodatnými odchylkami celkových přesností klasifikací nejlepších dvojic parametrů signálů z akcelerometru a gyroskopu za využití obou počtů nejbližších sousedů jsou uvedeny v tabulce 4.5, společně s hodnotami senzitivity a specificity. Opět všechny dvojice parametrů lépe klasifikují negativní pozorování, a tudíž mají vyšší hodnotu specificity. Výsledné hodnoty prvních pěti klasifikačních dvojic, které dosahují podobných výsledků, lze nalézt v tabulce G.2 v příloze G.

Tabulka 4.5: Dvojice parametrů akcelerometru a gyroskopu s nejvyšší přesností klasifikace K-NN s počtem nejbližších sousedů 3 a 5, spolu s ostatními hodnotícími kritérii.

Akcelerometr					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Počet sousedů	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{7Hz} RC	<i>ApEn</i> LO	3	85.71 ± 20.20	78.77 ± 30.70	90 ± 22.36
<i>RMS</i> LC	PSD_{0-4Hz} LC	5	82.86 ± 11.95	75.33 ± 23.29	96 ± 8.94
Gyroskop					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Počet sousedů	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
<i>RMS</i> RC	PSD_{0-4Hz} LC	3	88.57 ± 11.95	73.33 ± 25.28	100 ± 0
<i>RMS</i> LO	<i>P-P</i> RC	5	88.57 ± 11.95	81.67 ± 20.75	96 ± 8.94

Celkovou přesnost klasifikace nad 70 % dosáhlo 61 dvojic parametrů signálů akcelerometru s použitím tří nejbližších sousedů a 89 dvojic parametrů signálů akcelerometru s pěti nejbližšími sousedy. U gyroskopu tuto přesnost mělo 143 dvojic se třemi nejbližšími sousedy a 162 dvojic s využitím pěti nejbližších sousedů. Klasifikace s pěti nejbližšími sousedy dosahuje této přesnosti u více dvojic. Celkově ze všech vyzkoušených možností klasifikací K-NN dosahovaly dvojice parametrů gyroskopu přibližně o 3 % vyšších přesností oproti dvojicím parametrů dat z akcelerometru.

4.3.3 SVM

Při SVM klasifikaci byl vyzkoušen přístup jak se Soft margin, tak bez něj, neboli tvrdé SVM. V obou případech byla použita klasifikace s lineárním jádrem. Přesnější popis SVM klasifikace je obsažen v podkapitole 3.4.3. Každá dvojice parametrů akcelerometru a gyroskopu tedy byla klasifikována pomocí SVM dvakrát.

Přesnosti klasifikací dosahovaly pro oba přístupy SVM klasifikace téměř stejných hodnot. Nejvyšší přesnosti u SVM klasifikace dosáhla dvojice parametrů gyroskopu PSD_{7Hz} z měření pravé ruky se zavřenýma očima s PSD_{0-4Hz} z měření levé ruky se zavřenýma očima. Tato dvojice dosáhla přesnosti (91.43 ± 12.78) % jak u přístupu Soft margin. Celková přesnost klasifikace dvojice parametrů signálu gyroskopu s přístupem tvrdého SVM je o 0.5 % nižší.

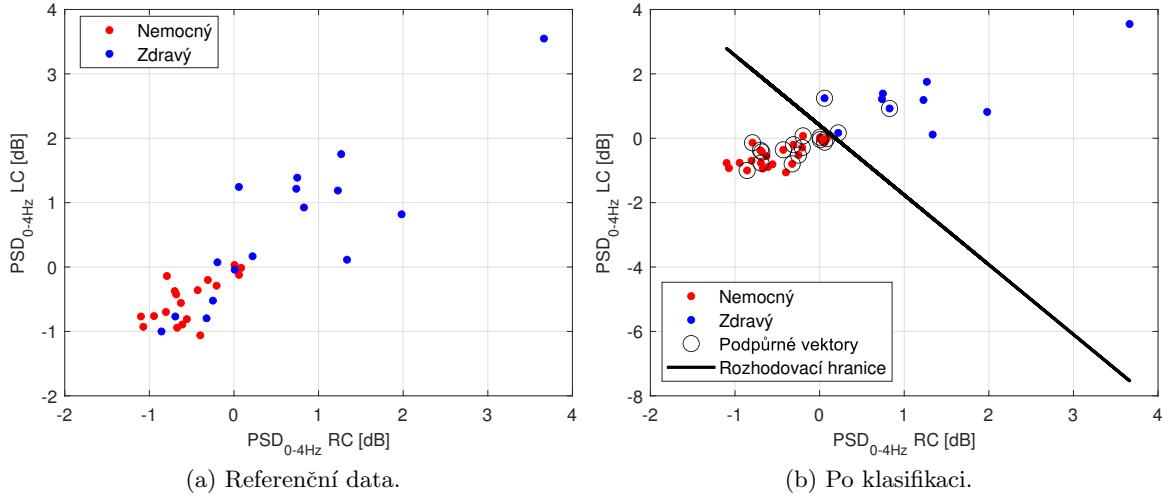
Celkově dvojice parametrů ze signálů gyroskopu dosahují přibližně o 9 % vyšší celkové přesnosti klasifikace než dvojice parametrů signálů z akcelerometru. V tabulce 4.6 jsou uvedeny dvojice parametrů, které dosáhly nejvyšších přesností u obou přístupů SVM klasifikace. Všechny dvojice lépe klasifikují zdravou skupinu účastníku, tedy dosahují vyšších hodnot specificity. Prvních pět dvojic parametrů dosahující nejvyšších celkových přesností je uvedeno společně s hodnotami hodnotících kritérií v tabulce G.3 v příloze G.

Tabulka 4.6: Dvojice parametrů akcelerometru a gyroskopu s nejvyšší přesností klasifikace SVM s využitím přístupu Soft margin a tvrdé SVM, spolu s ostatními hodnotícími kritérii.

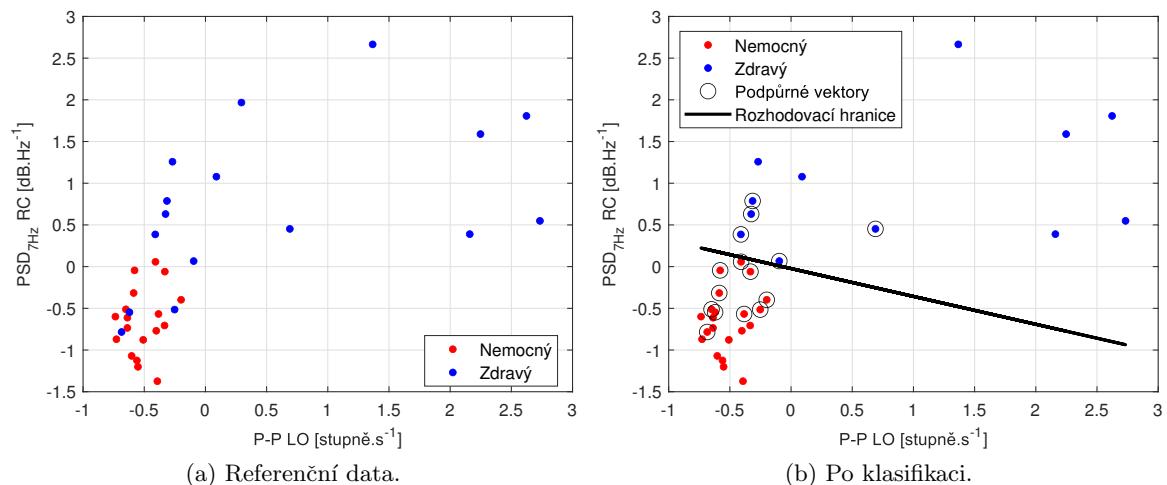
Akcelerometr					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Přístup	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{0-4Hz} LO	$ApEn$ RC	Tvrde SVM	82.38 ± 6.21	70 ± 24.01	95 ± 11.18
PSD_{0-4Hz} RC	PSD_{0-4Hz} LC	Soft margin	82.38 ± 15.58	51 ± 40.37	100 ± 0
Gyroskop					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Přístup	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
$P-P$ LO	PSD_{7Hz} RC	Tvrde SVM	90.95 ± 8.32	70 ± 41.08	100 ± 0
PSD_{7Hz} RC	PSD_{0-4Hz} LO	Soft margin	91.43 ± 12.78	83.33 ± 23.57	100 ± 0

S přístupem Soft margin dosáhlo celkové přesnosti klasifikace nad 70 % 133 dvojic parametrů signálů akcelerometru a 189 dvojic parametrů signálů gyroskopu. U přístupu s tvrdým SVM této přesnosti dosáhlo opět 146 dvojic parametrů signálů akcelerometru a 195 dvojic parametrů signálů gyroskopu.

Na obrázku 4.3 je znázorněná dvojice parametrů signálů akcelerometru, která dosáhla nejvyšší celkové přesnosti klasifikace s přístupem Soft margin. Je zde vidět původní přiřazení bodů ke skupinám s následnou změnou po klasifikaci společně s vykreslenou rozhodovací hranicí. Tento klasifikační model je natrénován na celém datasetu použitém v této práci. S použitím trénovacích množin, které se vytváří v průběhu křížové validace, se jednotlivé modely mohou mírně lišit. Dvojice parametrů signálů gyroskopu s nejvyšší přesností dosaženou za použití klasifikace s tvrdým SVM je znázorněna na obrázku 4.4. Opět je zde znázorněno jak původní přiřazení bodů do skupin, tak jejich změna po klasifikaci společně s rozhodovací hranicí mezi skupinami, která byla vytvořena modelem natrénovaným na celém datasetu.



Obrázek 4.3: Znázornění dvojice parametrů akcelerometru s nejvyšší celkovou přesností SVM klasifikace s přístupem Soft margin. Na obrázku (a) lze vidět dvojici parametrů před klasifikací se znázorněním jednotlivých skupin zdravý/nemocný. Na obrázku (b) je poté vidět změna přiřazení bodů do skupin po klasifikaci spolu s rozhodovací hranicí.



Obrázek 4.4: Znázornění dvojice parametrů gyroskopu s nejvyšší celkovou přesností SVM klasifikace s přístupem tvrdého SVM. Na obrázku (a) lze vidět dvojici parametrů před klasifikací se znázorněním jednotlivých skupin zdravý/nemocný. Na obrázku (b) je poté vidět změna přiřazení bodů do skupin po klasifikaci spolu s rozhodovací hranicí.

4.3.4 Naivní Bayesův klasifikátor

Pro vytvoření modelů naivního Bayesova klasifikátoru byl použit Gaussovský pravděpodobnostní model rozložení dat. Rozhodovací kontury pro jednotlivé skupiny pak mají tvar elips.

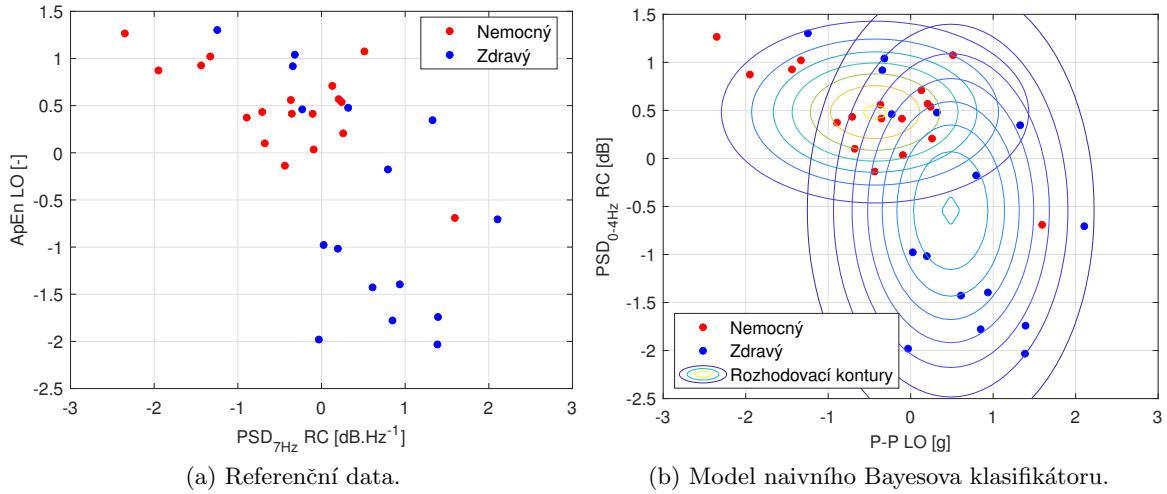
Dvojice parametrů dosahující nejlepších výsledků u naivní Bayesovy klasifikace byla složena z parametrů signálů gyroskopu $P-P$ z měření levé ruky s otevřenýma očima a PSD_{7Hz} z měření pravé ruky se zavřenýma očima. Tato dvojice dosáhla celkové přesnosti klasifikace $(91.43 \pm 12.78) \%$ se specificitou 100 %. Celková přesnost klasifikace dvojice parametrů, která dosáhla nejlepších výsledků pro klasifikaci signálů akcelerometru, je přibližně o 7.5 % nižší. Výsledky dvojcic parametrů signálů akcelerometru a gyroskopu s nejvyššími přesnostmi klasifikace, i s jejich hodnotami, jsou vypsané v tabulce 4.7. Prvních pět dvojcic s nejvyššími celkovými přesnostmi klasifikace, společně s hodnotami senzitivity a specificity, je uvedeno v tabulce G.4 v příloze G.

Tabulka 4.7: Dvojice parametrů signálů akcelerometru a gyroskopu s nejvyšší přesností naivního Bayesova klasifikátoru spolu s ostatními hodnotícími kritérii.

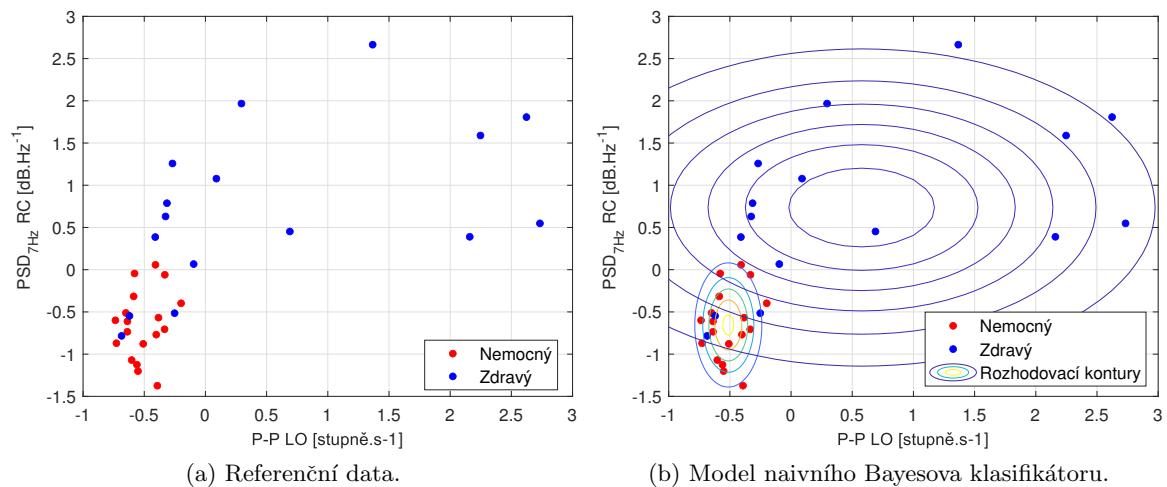
Akcelerometr				
		ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{7Hz} RC	aApEn LO	82.86 ± 18.63	68.33 ± 33.54	95 ± 11.18
Gyroskop				
		ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
$P-P$ LO	PSD_{7Hz} RC	91.43 ± 12.78	82.67 ± 28.91	100 ± 0

Na obrázku 4.5 je znázorněná dvojice parametrů signálů akcelerometru, která dosáhla nejvyšší celkové přesnosti klasifikace, společně s jejím modelem naivního Bayesova klasifikátoru. K vytvoření tohoto modelu byl použit celý dataset. Při trénování a následném hodnocení jednotlivých modelů bylo použito pouze 80 % náhodně vybraných dat. Na obrázku 4.6 je pak znázorněn model naivního Bayesova klasifikátoru vytvořený z dvojice parametrů signálů gyroskopu, která dosáhla nejvyšší celkové přesnosti. Opět je model vytvořen za použití celého datasetu. U obou obrázků jsou zakreslena jak samotná data, tak data společně s vytvořeným pravděpodobnostním klasifikačním modelem.

Celkem 142 dvojcic parametrů signálů akcelerometru dosáhlo celkové přesnosti klasifikace nad 70 %. Této přesnosti dosáhlo 206 dvojcic parametrů signálů gyroskopu, z celkového počtu 210 dvojcic.



Obrázek 4.5: Znázornění modelu naivního Bayesova klasifikátoru natrénovaného na dvojici parametrů signálů akcelerometru s nejvyšší celkovou klasifikační přesností. Na obrázku (a) jsou znázorněna původní data bez modelu, který je znázorněn pomocí rozhodovacích kontur na obrázku (b).



Obrázek 4.6: Znázornění modelu naivního Bayesova klasifikátoru natrénovaného na dvojici parametrů signálů gyroskopu s nejvyšší celkovou klasifikační přesností. Na obrázku (a) jsou znázorněna původní data bez modelu, který je znázorněn pomocí rozhodovacích kontur na obrázku (b).

4.4 Výsledky klasifikací trojic parametrů

Ke zvýšení klasifikační přesnosti bylo vyzkoušeno trénování klasifikačních modelů pomocí trojic parametrů. Trojice byly vytvářeny dvěma různými způsoby bez použití všech parametrů a za pomoci již vzniklých dvojic parametrů a jejich klasifikačních výsledků. Vytvoření trojic proběhlo opět pro parametry signálů akcelerometru a gyroskopu zvlášť.

První způsob spočíval ve výběru tří nejčastěji se vyskytujících parametrů mezi prvními patnácti dvojicemi s nejvyšší klasifikační přesností pro daný klasifikátor. Z parametrů, které měly tři nejvyšší četnosti, se následně nakombinovaly všechny možné trojice bez opakování. Nemuselo se jednat o právě tři parametry, tedy pouze jednu trojici parametrů pro daný klasifikátor, protože jednu ze tří nejvyšších četností mohlo mít více parametrů. Počet trojic byl tedy různý jak mezi klasifikátory, tak mezi parametry dat z akcelerometru a gyroskopu.

Druhý způsob spočíval ve vytvoření dvou trojic z kombinací prvních dvou dvojic s nejvyšší přesností pro daný klasifikátor. Pro vytvoření jedné trojice byl k první dvojici parametrů s nejvyšší přesností klasifikace přidán jeden parametr z dvojice, která měla druhou nejvyšší přesnost. Následně druhá trojice vznikla tak, že k první dvojici byl přidán druhý parametr z druhé dvojice, který nebyl využit u první trojice. Počet trojic byl ve všech případech stejný, měnily se pouze parametry, ze kterých byly trojice složeny. Pokud se ve druhé dvojici vyskytoval jeden z parametrů dvojice první, byla vytvořena pouze jedna trojice.

Trojice byly vytvořeny pro dva klasifikační algoritmy, které dosahovaly nejvyšších klasifikačních přesností s dvojicemi parametrů. Jednalo se tedy o klasifikátor SVM společně s navinným Bayesovým klasifikátorem. Jednotlivé klasifikace byly opět vyhodnoceny 5-fold křížovou validací s výpočtem celkové přesnosti klasifikace, senzitivity a specificity. U parametrů stále platí označení R/L (pravá/levá horní končetina) a O/C (otevřené/zavřené oči).

4.4.1 SVM

U klasifikace dvojic parametrů byly použity dva přístupy SVM, které dosahovaly téměř stejných výsledků. Pro klasifikaci trojic parametrů byl zvolen pouze SVM s tvrdým přístupem. Z nejčetnějších parametrů prvních 15 dvojic byly vytvářeny celkem 4 trojice parametrů signálů akcelerometru a 4 trojice parametrů signálů gyroskopu. Ve druhém případě vytvoření trojic, přidáním parametrů k dvojici první, byly parametry z dvojice s druhou nejvyšší přesností odlišné, vytvořily se tedy dvě rozdílné trojice parametrů.

Celkově ze všech možností SVM klasifikací trojic dosáhla nejvyšší přesnosti trojice parametrů dat gyroskopu složená z $P-P$ z měření levé ruky s otevřenýma očima, PSD_{7Hz} z měření pravé ruky se zavřenýma očima a RMS z měření levé ruky se zavřenýma očima. Trojice byla vytvořena přidáním parametrů k první dvojici a dosáhla přesnosti klasifikace $(88.57 \pm 11.95)\%$. Přesnosti klasifikací trojic parametrů signálů gyroskopu jsou přibližně o 5 % vyšší, oproti klasifikacím trojic ze signálů akcelerometru. Trojice vytvořené různými způsoby dosahují při klasifikaci podobných výsledků. V tabulce 4.8 jsou uvedené obě trojice parametrů, vytvořené přidáním parametru k první dvojici, společně s trojicí parametrů vytvořenou z nejčetnějších parametrů, která dosáhla nejvyšší klasifikační přesnosti. Jsou zde uvedené trojice jak pro data akcelerometru, tak gyroskopu, společně s výslednými hodnotami hodnotících kritérií. Z tabulky je zřejmé, že ve všech případech specificita dosahuje vyšších hodnot oproti senzitivitě, tedy modely lépe klasifikují zdravou skupinu účastníků.

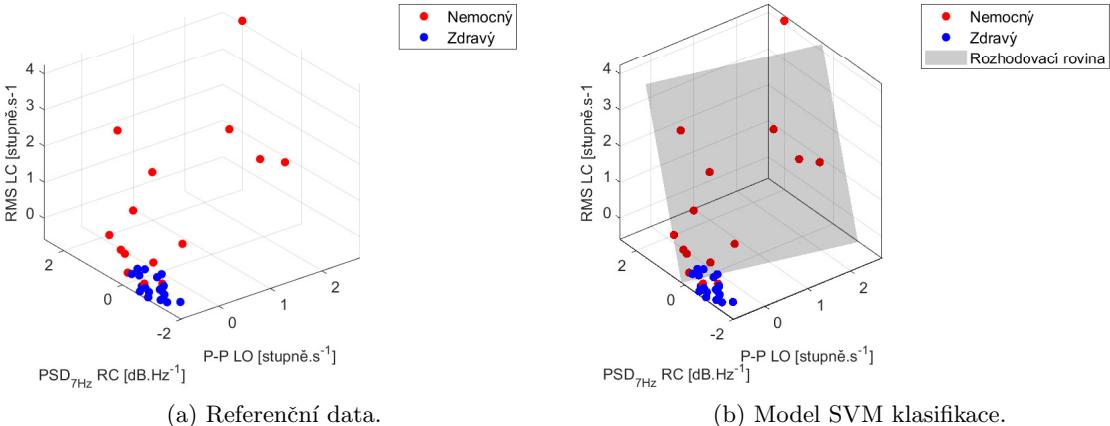
Hodnoty nejvyšších dosažených celkových přesnosti klasifikací trojic parametrů jsou podobné nebo nižší oproti klasifikacím dvojic parametrů. Ke zlepšení klasifikační přesnosti

a zvýšení výsledků hodnotících kritérií tedy nedošlo. Všechny trojice vytvořené z nejčetnějších parametrů společně s jejich hodnotícími kritérii jsou uvedeny v tabulce H.1 v příloze H.

Tabulka 4.8: Trojice parametrů signálů akcelerometru a gyroskopu, vytvořené přidáním k první dvojici, společně s trojicí vytvořenou z nejčetnějších parametrů, která dosáhla nejvyšší celkové přesnosti SVM klasifikace.

Akcelerometr						
Parametr 1	Parametr 2	Parametr 3	Vytvoření trojice	ACC [%]	SEN [%]	SPE [%]
PSD_{0-4Hz} LC	RMS LC	PSD_{0-4Hz} RC	Četnost parametrů	μ 81.90 σ 13.21	66 25.86	100 0
PSD_{0-4Hz} LO	$ApEn$ RC	RMS LC	Přidáním k první dvojici	μ 82.86 σ 15.65	73.33 25.28	95 11.12
PSD_{0-4Hz} LO	$ApEn$ RC	PSD_{0-4Hz} RC	Přidáním k první dvojici	μ 77.14 σ 16.29	63.33 41.50	86.67 29.81
Gyroskop						
Parametr 1	Parametr 2	Parametr 3	Vytvoření trojice	ACC [%]	SEN [%]	SPE [%]
PSD_{0-4Hz} LO	PSD_{max} LO	PSD_{7Hz} RC	Četnost parametrů	μ 88.10 σ 12.14	81.67 29.11	93.33 14.91
$P-P$ LO	PSD_{7Hz} RC	RMS LC	Přidáním k první dvojici	μ 88.57 σ 11.95	78.33 21.73	100 0
$P-P$ LO	PSD_{7Hz} RC	PSD_{7Hz} RC	Přidáním k první dvojici	μ 85.24 σ 17.53	83 26.36	93.33 14.91

Na obrázku 4.7 je znázorněná trojice parametrů signálů gyroskopu, která dosáhla nejvyšší přesnosti SVM klasifikace. Jsou zde znázorněna původní data, spolu s modelem rozdovací roviny. Tento klasifikační model byl natrénován na všech dostupných datech.



Obrázek 4.7: Znázornění SVM klasifikátoru s použitím všech dat trojice parametrů signálů gyroskopu. Na obrázku (a) jsou původní data bez modelu, který je znázorněn pomocí rozdovací roviny na obrázku (b).

4.4.2 Naivní Bayesův klasifikátor

Pro naivní Bayesův klasifikátor bylo vytvořeno z nejčetnějších parametrů celkem 10 trojic parametrů signálů akcelerometru a také 10 trojic parametrů signálů gyroskopu. Přidáním parametrů k první dvojici s nejvyšší přesností byly vytvořeny dvě trojice dat akcelerometru a pouze jedna trojice dat gyroskopu, neboť se ve druhé dvojici vyskytoval jeden totožný parametr, jako ve dvojici první.

Nejvyšší přesnosti (88.57 ± 12.14) % dosáhla trojice parametrů gyroskopu vytvořená z nejčetnějších parametrů. Trojice byla složena z parametrů PSD_{max} z měření levé ruky se zavřenýma očima, PSD_{0-4Hz} z měření levé ruky s otevřenýma očima a PSD_{max} z měření levé ruky s otevřenýma očima. Klasifikace trojic parametrů signálů gyroskopu dosahuje přibližně o 6 % vyšší přesnosti oproti klasifikaci trojic parametrů signálů akcelerometru. Výsledky celkových přesností mezi různými způsoby vytvoření trojic se opět příliš neliší. V tabulce 4.9 jsou všechny trojice parametrů vytvořené přidáním parametru k první dvojici, společně s trojicí vytvořenou z nejčetnějších parametrů, která dosahuje nejvyšších přesností jak pro data akcelerometru, tak gyroskopu. Jsou zde uvedeny výsledky hodnotících kritérií, kde ve všech případech specificita dosahuje vyšších hodnot oproti senzitivitě.

Ke zlepšení klasifikačních schopností nedošlo, celkově trojice dosahují stejných nebo nižších přesností klasifikace, oproti klasifikacím dvojic parametrů. Všechny trojice vytvořené z nejčetnějších parametrů společně s jejich hodnotícími kritérií jsou uvedeny v tabulce H.2 v příloze H.

Tabulka 4.9: Trojice parametrů signálů akcelerometru a gyroskopu, vytvořené přidáním k první dvojici, společně s trojicí vytvořenou z nejčetnějších parametrů, která dosáhla nejvyšší celkové přesnosti naivní Bayesovy klasifikace.

Akcelerometr						
Parametr 1	Parametr 2	Parametr 3	Vytvoření trojice	ACC [%]	SEN [%]	SPE [%]
$ApEn$ LC	$P-P$ LO	$ApEn$ RC	Četnost parametrů	μ 81.90 σ 16.63	75 25.86	93.33 14.91
PSD_{7Hz} RC	$ApEn$ LO	$P-P$ LO	Přidáním k první dvojici	μ 82.38 σ 11.86	68.33 20.75	95 11.18
PSD_{7Hz} RC	$ApEn$ LO	$ApEn$ LC	Přidáním k první dvojici	μ 73.81 σ 18.29	61.67 36.16	85 33.54
Gyroskop						
Parametr 1	Parametr 2	Parametr 3	Vytvoření trojice	ACC [%]	SEN [%]	SPE [%]
PSD_{max} LC	PSD_{0-4Hz} LO	PSD_{max} LO	Četnost parametrů	μ 88.57 σ 12.14	75 29.11	100 0
$P-P$ LO	PSD_{7Hz} RC	RMS LO	Přidáním k první dvojici	μ 88.10 σ 6.73	77.67 13.72	100 0

4.5 Studie rozšíření použitých klasifikačních metod

U dvou nejúspěšnějších klasifikačních metod byla vyzkoušena určitá rozšíření, která by mohla být nápmocná při praktickém využití daných klasifikátorů. Pro metodu SVM bylo vyzkoušeno použití více klasifikačních dvojic, na jejichž základě se určuje finální přiřazená třída pro dané pozorování. Pro naivní Bayesův klasifikátor byla přidána třetí rozhodovací třída, která byla danému pozorování přiřazena v případě nízké pravděpodobnosti přiřazení k původním dvěma třídám.

4.5.1 Rozhodování na principu hlasování SVM klasifikátorů

Pro využití více vypočítaných parametrů bylo vyzkoušeno použití více klasifikačních dvojic s následným principem hlasování o finální třídě pro dané pozorování. Princip hlasování spočívá v přiřazení té třídy, která se vyskytuje nejčastěji. Protože jsou data klasifikována do dvou tříd, bylo vybráno liché číslo počtu klasifikačních dvojic. Bylo použito devět dvojic parametrů, které dosahovaly nejvyšší přesnosti SVM klasifikace s tvrdým přístupem. Každá z devíti dvojic vytvořila klasifikační model bez jednoho náhodně vybraného pozorování, pro které proběhlo následné hlasování o výsledném přiřazení třídy. Tento postup byl opakován pro deset náhodně vybraných pacientů. Model byl tedy vždy natrénován na všech datech kromě jednoho náhodně vybraného pozorování. Opět byl tento postup vyzkoušen jak pro dvojice parametrů signálů akcelerometru, tak pro dvojice parametrů signálů gyroskopu.

Vzhledem k tomu, že byl tento přístup vyzkoušen na datech, u kterých je známé jejich správné přiřazení tříd, bylo možné rovnou určit, zda daná klasifikační dvojice přiřadila pacientovi správnou třídu, či nikoli. Výsledky přiřazení tříd z prvních devíti klasifikačních dvojic pro deset náhodně vybraných pacientů jsou znázorněny v tabulce 4.10. Číslo 1 značí správně přiřazenou třídu, 0 značí špatně přiřazenou třídu. Výsledná třída je poté určena jako ta nejčetnější ze všech přiřazených tříd. V reálném případě, kdy nejsou dopředu známé správné třídy pozorování, by v tabulce byly vypsány výsledné třídy určené danou klasifikační dvojicí. V tomto případě jsou v tabulce 4.10 vypsány hodnoty, které značí správné/špatné přiřazení tříd. Dvojice parametrů dat akcelerometru i gyroskopu byly trénovány vždy na stejně množině dat a následně testovány na stejném náhodně vybraném pacientovi. V tabulce si lze všimnout, že v případě pacienta číslo 3 klasifikovaly dvojice parametrů signálů gyroskopu pacienta správně, zatímco dvojice parametrů signálů akcelerometru nikoli. Tímto přístupem bylo možné využít více dostupných dat o daném pacientovi.

Tabulka 4.10: Přiřazení tříd náhodně vybraných pacientů na principu hlasovaní SVM klasifikátorů. 0 = špatně přiřazená třída, 1 = správně přiřazená třída.

Akcelerometr										
Číslo pacienta	Náhodně vybraný pacient									
	1	2	3	4	5	6	7	8	9	10
Výsledné třídy prvních devíti kla- sifikačních dvojic	0	1	0	1	1	1	1	1	1	1
	0	1	0	1	1	1	1	1	1	1
	0	1	0	1	1	1	1	1	1	1
	0	1	0	1	1	1	1	1	1	1
	0	1	0	0	1	1	1	1	1	1
	0	1	0	1	1	1	1	1	1	1
	0	1	0	1	1	1	1	0	1	1
	0	1	0	1	1	1	1	1	1	1
	0	1	0	1	1	1	1	1	1	1
Výsledná třída	0	1	0	1	1	1	1	1	1	1
Gyroskop										
Číslo pacienta	Náhodně vybraný pacient									
	1	2	3	4	5	6	7	8	9	10
Výsledné třídy prvních devíti kla- sifikačních dvojic	0	1	1	1	1	1	1	1	1	1
	0	1	1	1	1	1	1	1	1	1
	0	1	1	1	1	1	1	1	1	1
	0	1	0	1	1	1	1	1	1	1
	0	1	0	1	1	1	1	1	1	1
	0	1	1	1	1	1	1	1	1	1
	0	1	1	1	1	1	1	1	1	1
	0	1	1	1	1	1	1	1	1	1
	0	1	1	1	1	1	1	1	1	1
Výsledná třída	0	1	1	1	1	1	1	1	1	1

4.5.2 Zařazení třetí třídy pro naivní Bayesův klasifikátor

Naivní Bayesův klasifikátor přiřazuje výsledné třídy na základě pravděpodobnosti naležitosti k dané třídě. Každému bodu přiřadí počet pravděpodobností podle toho, do kolika tříd se data klasifikují. Při klasifikaci ale není zohledněno, jak velký je rozdíl mezi přiřazenými pravděpodobnostmi. To znamená, že i v téměř nerozhodném případě, kde by dané pozorování mohlo mít pravděpodobnost přiřazení k daným třídám 49 % a 51 %, přiřadí výslednou třídu s vyšším procentem bez ohledu na velikost rozdílu mezi pravděpodobnostmi. Pro tyto případy byla zavedena třetí třída, do kterých spadají ta pozorování, která mají nízký rozdíl mezi pravděpodobnostmi přiřazení do původních dvou tříd.

Data byla klasifikována zvlášť dvojicemi parametrů signálů akcelerometru a zvlášť gyroskopu. Opět byla využita 5-fold křížová validace, u které je model trénován na 80 % dat a zbylá jsou určená jako testovací. Při testování byly ukládány výsledně dvě posteriorní pravděpodobnosti, které určují přiřazení tříd. Následně byla určena prahová hodnota 70 %, která určuje dostatečně významnou pravděpodobnost přiřazení k dané třídě. Pokud byla větší posteriorní pravděpodobnost daného pozorování, tedy ta, která by přiřadila výslednou třídu, nižší než zavedená prahová hodnota, byla by místo jedné z původních dvou tříd přiřazena nově vytvořená třetí třída.

Tento přístup byl vyzkoušen na dvojicích parametrů, které dosáhly nejvyšších celkových přesností klasifikace pro signály akcelerometru a signály gyroskopu. S využitím 5-fold křížové validace je každý z pěti modelů trénován na rozdílné sadě dat a můžou se tak mírně lišit, nicméně každý pacient patří jednou do množiny testovacích dat. Výsledné přiřazené třídy všech pacientů, včetně nově vytvořené třetí třídy, byly ukládány. V obou případech, tedy jak klasifikace parametrů signálů akcelerometru, tak gyroskopu, byl téměř vždy jeden z pacientů klasifikován do třetí třídy, což znamená, že nedosahoval minimální pravděpodobnosti přiřazení 70 % k jedné ze dvou původních tříd.

Kapitola 5

Diskuze

V této kapitole je provedena diskuze nad výsledky klasifikací. První část 5.1 se zabývá výsledky klasifikací dvojic parametrů a druhá část 5.2 se zabývá výsledky klasifikací trojic parametrů. Poslední část 5.3 je zaměřena na navržená rozšíření a další možné návrhy.

Klasifikace do tříd zdravý/nemocný proběhla na datech naměřených akcelerometrem a gyroskopem na 34 dobrovolnících. Z celé skupiny účastníků 16 trpělo onemocněním RS a 18 byli zdraví jedinci. Všichni účastníci udali jako dominantní pravou ruku, žádný neměl dominantní levou ruku. U každého účastníka proběhla celkem 4 měření, která byla nahrávána jak akcelerometrem, tak gyroskopem. Měření byla prováděna na pravé, tedy dominantní, a levé horní končetině (u parametrů značené R/L) s otevřenýma/zavřenýma očima (u parametrů značené O/C). Z každého měření bylo vypočítáno 9 různých parametrů. Na jednoho pacienta tedy připadalo celkem 36 parametrů dat akcelerometru a 36 parametrů dat gyroskopu. Tyto parametry byly následně statisticky testovány, zda jsou mezi skupinami pro daný parametr významné rozdíly a jsou tedy vhodné pro klasifikaci dat. Z parametrů, které měly statisticky významné rozdíly mezi skupinami, byly sestaveny dvojice a trojice parametrů, které sloužily jako vstupní data pro klasifikační algoritmy. Pro klasifikaci dat byly zvoleny algoritmy K-means, K-NN, SVM a naivní Bayesův klasifikátor. Všechny klasifikace byly hodnoceny 5-fold křížovou validací s výpočtem celkové přesnosti, specificity a senzitivity pro každou testovací skupinu a jejich následným zprůměrováním.

5.1 Klasifikace dvojic parametrů

Z parametrů se statisticky významnými rozdíly mezi skupinami bylo vytvořeno celkem 153 dvojic parametrů signálů akcelerometru a 210 dvojic parametrů signálů gyroskopu. Tyto dvojice následně sloužily jako vstupní data pro jednotlivé klasifikační metody.

První z použitých algoritmů ke klasifikaci dat byl K-means. Pro vypočítání vzdáleností mezi body byly využity Euklidovská a Manhattanská vzdálenost. Celkové přesnosti klasifikací dosahovaly u dvojic parametrů signálů gyroskopu až 85 %, téměř o 3 % více oproti dvojicím dat akcelerometru. Této přesnosti s využitím Euklidovské vzdálenosti dosáhla dvojice parametrů PSD_{7Hz} RC, PSD_{max} LO. S využitím Manhattanské vzdálenosti dosáhla téměř stejně přesnosti dvojice parametrů PSD_{7Hz} RC, $ApEn$ LO. Rozdíly přesností za využití různých vzdáleností nebyly příliš velké. Nicméně více dvojic parametrů dosahovalo přesnosti nad 70 % při klasifikaci dat s Manhattanskou vzdáleností, a to jak v případě dat z akcelerometru, tak v případě dat z gyroskopu. To může být způsobeno menší citlivostí Manhattanské vzdálenosti na odlehlá data oproti vzdálenosti Euklidovské. Nejčastěji se vyskytující parametry s nejvyššími přesnostmi byly z měření levé ruky s otevřenýma očima společně s parametry z měření pravé ruky se zavřenýma očima.

U K-NN klasifikace byla využita pouze Euklidovská vzdálenost se třemi a pěti nejbližšími sousedy. Klasifikace dat z gyroskopu dosáhly opět lepších výsledků oproti parametrům signálů z akcelerometru. Dvojice parametrů signálů gyroskopu dosáhly až 88 % celkové přesnosti, přibližně o 3 % více oproti parametrům signálů akcelerometru. S využitím tří nejbližších sousedů dosáhla této přesnosti dvojice parametrů $RMS\ RC$, $PSD_{0-4Hz}\ LC$. Stejné přesnosti s využitím pěti nejbližších sousedů dosáhla dvojice parametrů $RMS\ LO$, $P-P\ RC$. Přesnosti klasifikací mezi použitím různého počtu sousedů se příliš nelišily, nicméně více dvojic parametrů dosáhlo přesnosti nad 70 % s využitím pěti nejbližších sousedů. Větší počet sousedů mohl způsobit větší robustnost vůči lokálním anomaliím v datech, a proto ve více případech mohl dosáhnout lepších klasifikačních výsledků. Parametry s nejvyššími přesnostmi byly nejčastěji z měření levé ruky s otevřenýma očima a z měření pravé ruky se zavřenýma očima.

Klasifikace SVM byla vyzkoušena jak s přístupem Soft margin, tak bez něj. Výsledky obou přístupů byly téměř totožné. Mohlo to být způsobeno malým počtem odlehých hodnot, které nemusely být penalizovány v případě přístupu Soft margin. Nejlepších výsledků dosahovala dvojice parametrů signálů z gyroskopu $PSD_{7Hz}\ RC$ s $PSD_{0-4Hz}\ LO$, jejíž celková přesnost klasifikace byla 91 %, což bylo téměř o 9 % více než výsledky parametrů signálů z akcelerometru. Mezi dvojicemi s vyššími přesnostmi se opět objevovaly parametry z měření levé ruky s otevřenýma očima a z měření pravé ruky se zavřenýma očima.

Naivní Bayesův klasifikátor dosahoval také celkové přesnosti až 91 %. Jednalo se o dvojici parametrů signálů z gyroskopu $P-P\ LO$ s $PSD_{7Hz}\ RC$. Rozdíl přesnosti oproti dvojici parametrů signálů z akcelerometru byl přibližně 7.5 %. Dvojice parametrů s lepšími výsledky klasifikace byly častěji z měření levé ruky s otevřenýma očima a z měření pravé ruky se zavřenýma očima.

Celkově lze říci, že dvojice parametrů signálů gyroskopu popisují výsledné skupiny lépe než parametry dat z akcelerometru, neboť klasifikace dat z gyroskopu dosahují vyšších přesností u všech klasifikačních algoritmů, které byly vyzkoušeny. To může být způsobeno citlivostí gyroskopu na jemné změny úhlu, kterými lze lépe popsat třes ruky charakteristický pro různá neurologická onemocnění. Oproti tomu akcelerometr popisuje lineární zrychlení v dané ose, které nemusí zcela přesně odpovídat složenému pohybu třesu ruky. Gyroskop je tedy vhodnější k měření tremoru horní končetiny a následnou diagnostiku pacientů s RS. Dále se mezi dvojicemi s vyššími přesnostmi klasifikace častěji vyskytují parametry z měření levé ruky s otevřenýma očima a z měření pravé ruky se zavřenýma očima. Mohla by zde být závislost vyšší přesnosti klasifikace na těch parametrech, které jsou získány z dominantní ruky.

Klasifikátory SVM a naivní Bayesův klasifikátor dosahovaly přibližně o 3 % vyšších přesností než klasifikátory K-means a K-NN. Tyto výsledky mohly být způsobeny tím, že algoritmy SVM a naivní Bayesův klasifikátor jsou méně náchylné na nadmerné přizpůsobení datům (overfitting), a mohly tedy lépe generovat modely z trénovacích dat, kterým následně odpovídala i data testovací. Nicméně u většiny algoritmů dosahovala směrodatná odchylka přesnosti 10 % a více, která mohla být způsobena nízkým počtem trénovacích dat. Větší množství dat by tuto odchylku mohlo zmenšit. Dále měly všechny klasifikační modely vyšší hodnoty specificity než senzitivity, tedy lépe klasifikovaly zdravé účastníky studie z kontrolní skupiny. Hodnoty specificity dosahovaly 90–100 %, zatímco hodnoty senzitivity se pohybovaly ve většině případů mezi 80–90 %. Mohlo to být způsobeno nerovnoměrným zastoupením tří společně s rozložením dat, kdy pozorování ze zdravé skupiny mohla mít jednoznačnější a lépe klasifikovatelná uskupení.

Klasifikační metody SVM a naivní Bayes, které dosáhly celkové přesnosti klasifikace

91 %, by byly vhodné pro možné použití v oblasti diagnostiky. Pro stabilnější výsledky s menšími směrodatnými odchylkami přesnosti by bylo vhodné metody natrénovat na větším množství dat a znova ověřit jejich účinnost. Hodnoty senzitivity obou metod dosáhly 100 %, tedy velmi dobře klasifikují zdravé účastníky studie.

5.2 Klasifikace trojic parametrů

Ke klasifikaci s trojicemi parametrů byly vybrány algoritmy SVM s tvrdým přístupem a naivní Bayesův klasifikátor, které dosahovaly nejvyšších přesností. Cílem bylo zlepšení výsledků klasifikace za použití většího množství dat. Trojice byly vytvořeny dvěma různými způsoby, které jsou blíže popsány v podkapitole 4.4.

Klasifikace SVM dosahovala přesnosti až 88 % za použití trojice parametrů $P\text{-}P$ LO, PSD_{7Hz} RC s RMS LC z dat gyroskopu. Data z gyroskopu dosahovala o 5 % vyšší přesnosti než parametry z dat akcelerometru. Způsoby vytvoření trojic neměly na klasifikaci téměř žádný dopad, protože dosahovaly téměř stejných výsledků jak u dat z akcelerometru, tak u dat z gyroskopu.

Naivní Bayesův klasifikátor dosahoval přesnosti také až 88 % u trojice parametrů PSD_{max} LC, PSD_{0-4Hz} LO s PSD_{max} LO z dat gyroskopu, což bylo přibližně o 6 % více než trojice parametrů dat z akcelerometru. Způsob vytvoření trojic opět neměl na klasifikaci téměř žádný vliv a trojice dosahovaly podobných výsledků.

Opět se u obou algoritmů mezi trojicemi parametrů s nejvyššími přesnostmi vyskytovaly častěji parametry z měření levé ruky s otevřenýma rukama a z měření pravé ruky se zavřenýma očima. Celkově z těchto výsledků vyplývá, že trojice parametrů dosahují nižších nebo podobných celkových přesností klasifikací jako dvojice parametrů. Hodnoty senzitivity jsou u klasifikace trojic parametrů spíše nižší než u klasifikace dvojic parametrů, zatímco hodnoty specificity se příliš nezměnily. Mohlo zde dojít k nadmernému přizpůsobení datům klasifikačním modelem, kterému by se dalo předejít s větším množstvím trénovacích dat. Přestože výsledky nejsou lepší než výsledky klasifikací dvojic, opět zde dochází k lepším výsledkům klasifikace dat z gyroskopu, než z akcelerometru. Tím se potvrzuje, že data z gyroskopu pravděpodobně lépe popisují pohyb tremoru u pacientů s RS. Všechny modely měly opět vyšší hodnoty specificity než senzitivity. Rozdíl mezi hodnotami mohl být opět způsoben zařazením tříd v datech společně s jejich rozložením.

5.3 Možnosti rozšíření použitých metod

V této práci byla navrhнута a vyzkoušena rozšíření dvou nejúspěšnějších klasifikačních metod. Rozšíření byla navržena pro algoritmy SVM a naivní Bayesův klasifikátor. Pro metodu SVM bylo navrženo rozšíření, kdy byla pacientovi přiřazena výsledná třída na principu hlasování klasifikátorů. Aby nedocházelo k nerozhodnému přiřazení třídy, bylo využito výsledků z prvních devíti dvojic parametrů, které dosahovaly nejlepších výsledků klasifikace. Pacientovi byla následně přiřazena ta třída, která převažovala u devíti daných klasifikačních dvojic. Pomocí tohoto rozšíření tak bylo využito více informací o daném pacientovi. Pro naivní Bayesův klasifikátor byly rozšířeny rozhodující třídy ze dvou na tři. Třetí třída byla přiřazena tomu pacientovi, který nedosahoval ani u jedné z původních dvou tříd pravděpodobnosti nad 70 %. Protože naivní Bayesův klasifikátor nerozhoduje nad významností velikosti rozdílu mezi přiřazenými pravděpodobnostmi, může zde dojít k přiřazení třídy s pravděpodobností pouhých

51 %. Do této třídy tedy spadla ta pozorování, která měla téměř nerozhodné přiřazení k jedné ze dvou původních tříd. Pacient tedy nemohl být zařazen do třídy s onemocněním RS nebo ke zdravým jedincům, pokud pravděpodobnost přiřazení k této třídě nebyla nad 70 %. Vždy minimálně jeden účastník ze všech byl přiřazen k nově vytvořené třetí třídě.

Dále by bylo vhodné podrobněji prozkoumat, zda mezi parametry vypočtenými z daného měření není určitá závislost na výsledné přesnosti klasifikace. Všechny parametry byly vypočteny ze čtyř různých měření. Klasifikace by mohly probíhat zvlášť pro každé měření, stejně jako to probíhalo zvlášť pro data z akcelerometru a gyroskopu. Následně by se mohlo porovnat, zda parametry z jednoho měření nedosahují lepších klasifikačních schopností než parametry z měření jiného. Jak se ukázalo ve výsledcích z klasifikací dvojic a trojic parametrů, často se mezi parametry s vyššími přesnostmi vyskytovaly ty, které byly vypočteny z měření levé ruky s otevřenýma očima a z měření pravé ruky se zavřenýma očima. Mohlo by to znamenat, že parametry z daného měření klasifikují lépe než parametry z měření jiného. Parametry z měření dominantní ruky by mohly mít lepší výsledky klasifikace než parametry z měření nedominantní ruky, nebo naopak. Pokud by parametry daného měření vykazovaly lepší klasifikační schopnosti než parametry z měření jiných, mohla by se ostatní měření ze studie vyřadit. Zmenšení počtu měření, a tím i počtu parametrů, by snížilo výpočetní náročnost algoritmů, a zároveň by pacient mohl podstoupit pouze jedno měření namísto čtyř. Popřípadě by bylo možné zkoumat rozdíl klasifikačních schopností parametrů z měření dominantní a nedominantní ruky. V této studii byli pouze účastníci s pravou dominantní rukou.

V této práci se zkoumala schopnost jednotlivých klasifikačních algoritmů pro data akcelerometru a gyroskopu zvlášť. Ukázalo se, že data z gyroskopu mají lepší schopnost klasifikovat data tremoru do skupin zdravý/nemocný. Některé parametry akcelerometru by nicméně mohly lépe zachycovat určitou vlastnost tremoru, která by spojení dat z obou senzorů by mohlo přinést lepší výsledky než klasifikace dat z jednotlivých senzorů zvlášť.

Kapitola 6

Závěr

Cílem této práce bylo najít vhodný klasifikační algoritmus společně s parametry signálů z akcelerometru a gyroskopu, které by byly schopné správně rozeznat, zda pacient trpí onemocněním RS, nebo nikoli. Dalším cílem bylo zjistit, který ze signálů je k této klasifikační úloze vhodnější. Pro klasifikaci byly použity čtyři různé klasifikační algoritmy s různou parametrizací. Jednalo se o algoritmy s učitelem K-NN, SVM a naivní Bayesův klasifikátor společně se shlukovacím algoritmem bez učitele K-means.

Klasifikace proběhla na dvojcích a trojcích parametrů složených z těch parametrů, které byly určeny ze statistických testů jako vhodné ke klasifikaci do tříd zdravý/nemocný. Všechny klasifikační přístupy byly vyhodnoceny 5-fold křížovou validací s výpočtem celkové přesnosti, senzitivity a specificity.

Zkoumány byly dva různé způsoby tvorby trojic z dvojic parametrů, které dosahovaly nejlepších výsledků u daných klasifikačních metod. Nicméně klasifikace trojic parametrů dosahovala stejných nebo horších výsledků jako klasifikace dvojic, proto nebyly trojice parametrů považovány za vhodné kandidáty ke klasifikaci dat a nebyly předmětem dalšího zkoumání.

Nejlepších výsledků klasifikace dosahovaly metody SVM a naivní Bayesův klasifikátor s použitím dvojic parametrů. Tyto klasifikační algoritmy byly vyhodnoceny jako vhodný kandidáti pro rozlišení pacientů s RS a zdravých jedinců pomocí dat z měření tremoru horní končetiny. U obou algoritmů dosahovala celková přesnost klasifikace až 91 %. Pro SVM algoritmus s přístupem Soft margin byla nejvhodnější dvojice parametrů, které byly vypočítány ze signálů gyroskopu, PSD_{7Hz} z měření pravé ruky se zavřenýma očima s PSD_{0-4Hz} z měření levé ruky s otevřenýma očima. Tato dvojice dosáhla přesnosti $(91.43 \pm 12.78) \%$ (střední hodnota \pm směrodatná odchylka). Dvojice s nejvyšší přesností pro naivní Bayesův klasifikátor byla také vypočítána ze signálů gyroskopu a jednalo se o $P-P$ z měření levé ruky s otevřenýma očima s PSD_{7Hz} z měření pravé ruky se zavřenýma očima. Tato dvojice dosáhla stejné celkové přesnosti klasifikace o hodnotě $(91.43 \pm 12.78) \%$ jako dvojice parametrů u metody SVM. Obě dvojice parametrů měly hodnoty specificity 100 %, tedy velmi dobře rozeznaly pozorování z kontrolní skupiny.

Všechny použité algoritmy vedly k lepším klasifikačním výsledkům při použití parametrů vypočítaných ze signálů gyroskopu. Měření tremoru horní končetiny pomocí gyroskopu by tedy mohlo být pro následnou diagnostiku pacientů s podezřením na onemocnění RS vhodnější než měření pomocí akcelerometru.

V této práci byla navíc navržena rozšíření klasifikačních metod s použitím algoritmů SVM a naivního Bayesova klasifikátoru. Pro SVM bylo navrženo použití principu hlasování prvních devíti klasifikačních dvojic parametrů s nejvyššími klasifikačními přesnostmi. Výsledná třída by byla pacientovi přiřazena na základě převažující třídy daných devíti klasifikačních dvojic. Tím by bylo použito více informací o daném pacientovi. Pro naivní Bayesův klasifikátor byla přidána třetí třída, ke které byl pacient přiřazen, pokud nespadal ani do jedné

z původních dvou tříd s pravděpodobností nad 70 %. Tím bylo zajištěno, aby nedošlo k též nerozhodné situaci, kdy by mohl být pacient přiřazen k třídě s pravděpodobností pouze 51 %. Třetí třída byla přiřazena vždy minimálně u jednoho pozorování.

Lepších výsledků s menšími směrodatnými odchylkami bylo pravděpodobně docíleno použitím většího množství vstupních dat, ideálně s vyrovnaným zastoupením jednotlivých tříd. Tím by mohla být dosažena i vyšší senzitivita klasifikačních algoritmů. Vytvoření databáze dat s měřením tremoru horní končetiny pomocí akcelerometru/gyroskopu u pacientů s RS a zdravých jedinců s následným testováním klasifikačních algoritmů by mohlo vést k vytvoření klasifikátoru, který by byl vhodný pro budoucí diagnostiku RS.

Reference

- [1] A. A. Asea, F. Geraci a P. Kaur, ed., *Multiple Sclerosis: Bench to Bedside*, sv. 958, Advances in Experimental Medicine and Biology, Cham: Springer International Publishing, 2017, ISBN: 978-3-319-47860-9 978-3-319-47861-6. DOI: [10.1007/978-3-319-47861-6](https://doi.org/10.1007/978-3-319-47861-6).
- [2] E. K. Havrdová, *Roztroušená skleróza v praxi*. Praha: Galén, 2015, ISBN: 978-80-7492-189-6.
- [3] A. Miller, ed., *Handbook of Relapsing-Remitting Multiple Sclerosis*, Cham: Springer International Publishing, 2017, ISBN: 978-3-319-40626-8 978-3-319-40628-2. DOI: [10.1007/978-3-319-40628-2](https://doi.org/10.1007/978-3-319-40628-2).
- [4] S. E. Hughes a G. Macaron, *Multiple sclerosis* (Fast facts), Fifth edition. Oxford [Freiburg]: Karger, 2021, 164 s., ISBN: 978-3-318-06797-2.
- [5] R. Ampapa, „Early symptoms and diagnosis of multiple sclerosis by the general practitioner,“ *Medicína pro praxi*, roč. 19, č. 3, s. 169–172, 16. čvn. 2022, ISSN: 12148687, 18035310. DOI: [10.36290/med.2022.026](https://doi.org/10.36290/med.2022.026).
- [6] D. Horáková, „Roztroušená skleróza a úloha praktického lékaře,“ *Medicína pro praxi*, roč. 10, č. 5, s. 378–382, 2008.
- [7] V. Sládková, „Diagnostika roztroušené sklerózy, typické klinické příznaky,“ *Medicína pro praxi*, roč. 12, č. 5, s. 236–242, 2015.
- [8] E. Růžička a P. Holly, „Clinical classification of tremor,“ *Neurologie pro praxi*, roč. 21, č. 6, s. 428–432, 6. led. 2021, ISSN: 12131814, 18035280. DOI: [10.36290/neu.2020.090](https://doi.org/10.36290/neu.2020.090).
- [9] P. G. Bain, „Tremor,“ *Parkinsonism & Related Disorders*, roč. 13, S369–S374, 2007, ISSN: 13538020. DOI: [10.1016/S1353-8020\(08\)70032-4](https://doi.org/10.1016/S1353-8020(08)70032-4).
- [10] J. Benetin, „Tremor - klasifikácia, diferenciálna diagnóza a terapia,“ *Neurologie pro praxi*, č. 1, s. 36–38, 2001.
- [11] G. Deuschl, P. Bain a M. Brin, „Consensus statement of the movement disorder society on tremor,“ *Movement Disorders*, roč. 13, s. 2–23, S3 20. říj. 2008, ISSN: 08853185, 15318257. DOI: [10.1002/mds.870131303](https://doi.org/10.1002/mds.870131303).
- [12] R. Capildeo a L. J. J. Findley, „Classification of tremor,“ in *Movement Disorders: Tremor*, L. J. Findley a R. Capildeo, ed., London: Palgrave Macmillan UK, 1984, s. 3–13, ISBN: 978-1-349-06759-6 978-1-349-06757-2. DOI: [10.1007/978-1-349-06757-2_1](https://doi.org/10.1007/978-1-349-06757-2_1).
- [13] R. J. Elble, „Tremor,“ in *Neuro-Geriatrics*, B. Tousi a J. Cummings, ed., Cham: Springer International Publishing, 2017, s. 311–326, ISBN: 978-3-319-56483-8 978-3-319-56484-5. DOI: [10.1007/978-3-319-56484-5_20](https://doi.org/10.1007/978-3-319-56484-5_20).
- [14] S. S. Ayache, M. A. Chalah, T. Al-Ani et al., „Tremor in multiple sclerosis: The intriguing role of the cerebellum,“ *Journal of the Neurological Sciences*, roč. 358, č. 1, s. 351–356, lis. 2015, ISSN: 0022510X. DOI: [10.1016/j.jns.2015.09.360](https://doi.org/10.1016/j.jns.2015.09.360).
- [15] S. H. Alusi, „A study of tremor in multiple sclerosis,“ *Brain*, roč. 124, č. 4, s. 720–730, 1. dub. 2001, ISSN: 14602156. DOI: [10.1093/brain/124.4.720](https://doi.org/10.1093/brain/124.4.720).
- [16] S. J. Pittock, R. L. McClelland, W. T. Mayr, M. Rodriguez a J. Y. Matsumoto, „Prevalence of tremor in multiple sclerosis and associated disability in the olmsted county population,“ *Movement Disorders*, roč. 19, č. 12, s. 1482–1485, pros. 2004, ISSN: 0885-3185, 1531-8257. DOI: [10.1002/mds.20227](https://doi.org/10.1002/mds.20227).
- [17] M. Koch, J. Mostert, D. Heersema a J. De Keyser, „Tremor in multiple sclerosis,“ *Journal of Neurology*, roč. 254, č. 2, s. 133–145, ún. 2007, ISSN: 0340-5354, 1432-1459. DOI: [10.1007/s00415-006-0296-7](https://doi.org/10.1007/s00415-006-0296-7).

- [18] P. McGurrin, J. Mcnames, T. Wu, M. Hallett a D. Haubenberger, „Quantifying tremor in essential tremor using inertial sensors—validation of an algorithm,“ *IEEE Journal of Translational Engineering in Health and Medicine*, roč. 9, s. 1–10, 2021, ISSN: 2168-2372. DOI: [10.1109/JTEHM.2020.3032924](https://doi.org/10.1109/JTEHM.2020.3032924).
- [19] S. Lambrecht, J. A. Gallego, E. Rocon a J. L. Pons, „Automatic real-time monitoring and assessment of tremor parameters in the upper limb from orientation data,“ *Frontiers in Neuroscience*, roč. 8, číslo 24. čvc. 2014, ISSN: 1662-453X. DOI: [10.3389/fnins.2014.00221](https://doi.org/10.3389/fnins.2014.00221).
- [20] K. Dimitrakopoulos, C. Ellmer, M. Lindstrom a A. Medvedev, „Tremor quantification through event-based movement trajectory modeling,“ in *2017 IEEE Conference on Control Technology and Applications (CCTA)*, Mauna Lani Resort, HI, USA: IEEE, srp. 2017, s. 542–547, ISBN: 978-1-5090-2182-6. DOI: [10.1109/CCTA.2017.8062518](https://doi.org/10.1109/CCTA.2017.8062518).
- [21] M. N. Alam, B. Johnson, J. Gendreau, K. Tavakolian, C. Combs a R. Fazel-Rezai, „Tremor quantification of parkinson's disease - a pilot study,“ in *2016 IEEE International Conference on Electro Information Technology (EIT)*, Grand Forks, ND, USA: IEEE, květ. 2016, s. 0755–0759, ISBN: 978-1-4673-9985-2. DOI: [10.1109/EIT.2016.7535334](https://doi.org/10.1109/EIT.2016.7535334).
- [22] A. Channa, R.-C. Ifrim, D. Popescu a N. Popescu, „A-WEAR bracelet for detection of hand tremor and bradykinesia in parkinson's patients,“ *Sensors*, roč. 21, č. 3, s. 981, 2. ún. 2021, ISSN: 1424-8220. DOI: [10.3390/s21030981](https://doi.org/10.3390/s21030981).
- [23] S. M. Ali, S. P. Arjunan, J. Peter et al., „Wearable accelerometer and gyroscope sensors for estimating the severity of essential tremor,“ *IEEE Journal of Translational Engineering in Health and Medicine*, roč. 12, s. 194–203, 2024, ISSN: 2168-2372. DOI: [10.1109/JTEHM.2023.3329344](https://doi.org/10.1109/JTEHM.2023.3329344).
- [24] J. M. Huisings, M. Mancini, R. J. St. George a F. B. Horak, „Accelerometry reveals differences in gait variability between patients with multiple sclerosis and healthy controls,“ *Annals of Biomedical Engineering*, roč. 41, č. 8, s. 1670–1679, srp. 2013, ISSN: 0090-6964, 1573-9686. DOI: [10.1007/s10439-012-0697-y](https://doi.org/10.1007/s10439-012-0697-y).
- [25] P. Kotíková, „Jak vypovídá vyšetření akcelerometrem o funkci horních končetin u nemocných s roztroušenou sklerózou mozkomíšní?“ Bakalářská práce, Univerzita Karlova, 3. lékařská fakulta, Praha, 2019.
- [26] D. Cattaneo, C. De Nuzzo, T. Fascia, M. Macalli, I. Pisoni a R. Cardini, „Risks of falls in subjects with multiple sclerosis,“ *Archives of Physical Medicine and Rehabilitation*, roč. 83, č. 6, s. 864–867, čvn. 2002, ISSN: 00039993. DOI: [10.1053/apmr.2002.32825](https://doi.org/10.1053/apmr.2002.32825).
- [27] R. R. Figueiredo, A. A. De Azevedo a P. De Mello Oliveira, „Correlation analysis of the visual-analogue scale and the tinnitus handicap inventory in tinnitus patients,“ *Brazilian Journal of Otorhinolaryngology*, roč. 75, č. 1, s. 76–79, led. 2009, ISSN: 18088694. DOI: [10.1016/S1808-8694\(15\)30835-1](https://doi.org/10.1016/S1808-8694(15)30835-1).
- [28] V. Mathiowetz, K. Weber, N. Kashman a G. Volland, „Adult norms for the nine hole peg test of finger dexterity,“ *The Occupational Therapy Journal of Research*, roč. 5, č. 1, s. 24–38, led. 1985, ISSN: 0276-1599. DOI: [10.1177/153944928500500102](https://doi.org/10.1177/153944928500500102).
- [29] M. R. Heldner, T. Vanbellingen, S. Bohlhalter, H. P. Mattle, R. M. Müri a C. P. Kamm, „Coin rotation task: A valid test for manual dexterity in multiple sclerosis,“ *Physical Therapy*, roč. 94, č. 11, s. 1644–1651, 1. lis. 2014, ISSN: 0031-9023, 1538-6724. DOI: [10.2522/ptj.20130252](https://doi.org/10.2522/ptj.20130252).
- [30] P. Horák, „Objektivizace vyšetření třesu pomocí akcelerometru,“ Bakalářská práce, Univerzita Karlova, 3. lékařská fakulta, Praha, 2018.
- [31] S. Theodoridis a K. Koutroumbas, *Pattern recognition*, 4th ed. Burlington, MA: Academic Press, 2009, OCLC: 610009838, ISBN: 978-1-59749-272-0.
- [32] M. Budíková, M. Králová a B. Maroš, *Průvodce základními statistickými metodami*. Praha: Grada, 2010, ISBN: 978-80-247-3243-5.
- [33] D. Sheskin, *Handbook of parametric and nonparametric statistical procedures*, 5th ed. Boca Raton: CRC Press, 2011, 1886 s., ISBN: 978-1-4398-5801-1.

- [34] G. W. Corder a D. I. Foreman, *Nonparametric statistics: a step-by-step approach*, Second edition. Hoboken, New Jersey: John Wiley & Sons, 2014, OCLC: 862222362, ISBN: 978-1-118-84042-9.
- [35] M. C. Bishop, „Mixture Models and EM,“ in *Pattern recognition and machine learning*, ř. Information science and statistics, New York: Springer, 2006, s. 423–455, ISBN: 978-0-387-31073-2.
- [36] J. Kelbel a D. Šilhán, *Shluková analýza*, 2009. URL: https://cmp.felk.cvut.cz/cmp/courses/recognition/zapis_prednasky/zapis_02/13/shlukovani.pdf.
- [37] F. Tarakci a I. Ozkan, „Comparison of classification performance of kNN and WKNN algorithms,“ *Selcuk University Journal of Engineering Sciences*, roč. 20, č. 2, s. 32–37, 2021, ISSN: 2757-8828. URL: <https://sujes.selcuk.edu.tr/sujes/article/view/536>.
- [38] J. Cervantes, F. Garcia-Lamont, L. Rodríguez-Mazahua a A. Lopez, „A comprehensive survey on support vector machine classification: Applications, challenges and trends,“ *Neurocomputing*, roč. 408, s. 189–215, 2020, ISSN: 0925-2312. URL: <https://www.sciencedirect.com/science/article/pii/S0925231220307153>.
- [39] D. Berrar, „Bayes' theorem and naive bayes classifier,“ in *Encyclopedia of Bioinformatics and Computational Biology*, Elsevier, 2019, s. 403–412, ISBN: 978-0-12-811432-2. DOI: [10.1016/B978-0-12-809633-8.20473-1](https://doi.org/10.1016/B978-0-12-809633-8.20473-1).
- [40] „Introduction,“ in *Pattern recognition and machine learning*, ř. Information science and statistics, New York: Springer, 2006, s. 1–66, ISBN: 978-0-387-31073-2.
- [41] N. Wang, N. N. Zeng a W. Zhu, „Sensitivity, specificity, accuracy, associated confidence interval and ROC analysis with practical SAS implementations,“ *NESUG proceedings: Health Care and Life Science*, 2010. URL: <https://www.lexjansen.com/nesug/nesug10/h1/h107.pdf>.

Příloha A

**Souhlas Etické komise Fakultní nemocnice
Královské Vinohrady**



**ETICKÁ KOMISE
FAKULTNÍ NEMOCNICE KRALOVSKÉ VINOHRADY
MEDICAL FACULTY OF CHARLES UNIVERSITY**

**ROZHODNUTÍ
MULTICENTRICKÉ ETICKÉ KOMISE FAKULTNÍ NEMOCNICE
KRÁLOVSKÉ VINOHRADY**

EK-VP/01/0/2018

NÁZEV PROJEKTU:

Využití virtuální reality ve fyzioterapii na funkci horní končetiny u pacientů s roztroušenou sklerózou

Hlavní řešitel ve FNKV: Doc. PhDr. Kamila Řasová, Ph.D.
Klinika rehabilitačního lékařství

Etická komise na svém zasedání dne **10. ledna 2018** projednala návrh vědeckého projektu doloženého následujícími dokumenty:

1. Žádost
2. Anotace projektu
3. Informovaný souhlas pacienta
4. Životopisy členů týmu
5. Souhlas přednostky kliniky

Na základě hlasování EK vydává

Souhlasné stanovisko
 Nesouhlasné stanovisko

Upozornění ke stanovisku EK FNKV:

- Hlavní řešitel je povinen ohlásit EK FNKV datum zahájení a ukončení projektu a zaslat závěrečnou zprávu.
- V případě, že z projektu vzejde publikace, je hlavní řešitel povinen publikaci dedikovat FNKV.

Seznam členů etické komise

Jméno a příjmení	Muž/ Žena	Odbornost	Zaměstnanec zřizovatele EK* Ano Ne	Funkce v EK	Přítomen Ano Ne	Hlasoval Ano Ne
prof. MUDr. Jan Pachl, CSc.	M	anesteziolog	<input checked="" type="checkbox"/> <input type="checkbox"/>	předseda	<input checked="" type="checkbox"/> <input type="checkbox"/>	<input checked="" type="checkbox"/> <input type="checkbox"/>
MUDr. Martin Herold	M	kardiolog	<input checked="" type="checkbox"/> <input type="checkbox"/>	místopředseda	<input checked="" type="checkbox"/> <input type="checkbox"/>	<input checked="" type="checkbox"/> <input type="checkbox"/>
MUDr. Milan Brychta	M	onkolog	<input checked="" type="checkbox"/> <input type="checkbox"/>	člen	<input checked="" type="checkbox"/> <input type="checkbox"/>	<input checked="" type="checkbox"/> <input type="checkbox"/>
Jarmila Folprechová	F	zástupce pacientů	<input type="checkbox"/> <input checked="" type="checkbox"/>	člen	<input checked="" type="checkbox"/> <input type="checkbox"/>	<input checked="" type="checkbox"/> <input type="checkbox"/>
PhDr. Libuše Gaylasová	F	zdravotní sestra	<input checked="" type="checkbox"/> <input type="checkbox"/>	člen	<input type="checkbox"/> <input checked="" type="checkbox"/>	<input type="checkbox"/> <input checked="" type="checkbox"/>
MUDr. Nikola Mejzlíková	F	internistka	<input checked="" type="checkbox"/> <input type="checkbox"/>	člen	<input type="checkbox"/> <input checked="" type="checkbox"/>	<input type="checkbox"/> <input checked="" type="checkbox"/>
Dana Kovandová	F	tajemnice	<input checked="" type="checkbox"/> <input type="checkbox"/>	člen	<input checked="" type="checkbox"/> <input type="checkbox"/>	<input checked="" type="checkbox"/> <input type="checkbox"/>
MUDr. Eva Krpenská	M	chirurg	<input checked="" type="checkbox"/> <input type="checkbox"/>	člen	<input checked="" type="checkbox"/> <input type="checkbox"/>	<input checked="" type="checkbox"/> <input type="checkbox"/>
Mgr. Petr Mlynář	M	farmakolog	<input checked="" type="checkbox"/> <input type="checkbox"/>	člen	<input checked="" type="checkbox"/> <input type="checkbox"/>	<input checked="" type="checkbox"/> <input type="checkbox"/>
Luboš Olejár	M	zástupce pacientů	<input type="checkbox"/> <input checked="" type="checkbox"/>	člen	<input checked="" type="checkbox"/> <input type="checkbox"/>	<input checked="" type="checkbox"/> <input type="checkbox"/>
MUDr. Leo Slavkovský	M	anesteziolog	<input checked="" type="checkbox"/> <input type="checkbox"/>	člen	<input type="checkbox"/> <input checked="" type="checkbox"/>	<input type="checkbox"/> <input checked="" type="checkbox"/>

(pozn: *Zaměstnanec zřizovatele EK)

Etická komise prohlašuje, že byla ustavena a pracuje podle jednacího řádu v souladu se správnou klinickou praxí (GCP) a platnými právními předpisy: Ano Ne

10.1.2018
Datum

Prof. MUDr. Jan Pachl, CSc.
předseda EK FNKV

Podpis předsedy/místopředsedy EK

K. Pachl
FAKULTNÍ NEMOCNICE
KRÁLOVSKÉ VINOHRAĐY
Šrobárova 50, 100 34 Praha 10
ETICKÁ KOMISE

Příloha B

Informovaný souhlas účastníka studie

Informovaný souhlas účastníka studie

VLIV FYZIOTERAPEUTICKÝCH FACILITAČNÍCH TECHNIK FUNKCI HORNÍ KONČETINY U PACIENTŮ S ROZTROUŠENOU SKLERÓZOU

Průběh a popis studie

Cílem tohoto projektu je zjistit vliv fyzioterapeutických intervencí na funkci horních končetin. Ve studii budou zaznamenány některé demografické údaje (věk, pohlaví, váha a výška) a data vztahující se k onemocnění (stupeň neurologického postižení, typ RS, délka trvání onemocnění, užívání léků).

Na hodnocení funkce horních končetin budou použité různé validované klinické testy (hodnotící sílu stisku a úchopu ruky, jemné a hrubé manuální zručnosti, manipulace s předměty, rychlosť a koordinaci horních končetin) dotazníkové testy pro subjektivní hodnocení funkce a aktivity horních končetin (škála spasticity, zraková analogová škála hodnotící slabost, únavu, citlivost; měření manuální schopnosti, dotazník hodnotící obtíže při provádění aktivit denního života, záznam motorické aktivity horní končetiny, motorické oslabení trupu při dynamických a statických pozicích v sedě).

Vyšetření třesu bude realizované pomocí akcelerometru, fixováneho na III. prst ruky pomocí akrylátového prstýnku (naměřený záznam bude přenesen do počítače, z kterého se budou odečítat potřebné hodnoty). Dále bude sledována variabilita srdečního rytmu.

Tato vyšetření budou provedena vyškoleným nezávislým fyzioterapeutem, a to celkem čtyřikrát v čase – měsíc před začátkem terapie, před terapií, hned po skončení rehabilitace a s odstupem dvou měsíců. Každé z těchto čtyř měření bude trvat 1-1,5 hodiny a budou probíhat na Neurologické klinice FNKV v Praze. V případě potřeby budou dělané přestávky, celková doba bude přizpůsobena Vaší fyzické a psychické kondici.

V rámci studie podstoupíte ambulantní fyzioterapeutický program zaměřen na funkci horních končetin a aktivity denního života (2 terapie dvakrát týdně po dobu jedné hodiny) v rozsahu dvou měsíců (16 terapeutických jednotek). V terapiích se bude vycházet z přirozených pohybů zdravého člověka a z pohybů denních činností.

Já, níže uvedený, dávám souhlas k účasti ve studii s názvem:

Vliv fyzioterapeutických facilitačních technik funkci horní končetiny u pacientů s roztroušenou sklerózou

Jméno:

Rodné číslo:

Identifikační kód.....

1. Zcela dobrovolně souhlasím s účastí v této studii.
2. Byl(a) jsem plně informován(a) o účelu této studie, o procedurách s ní souvisejících a o tom, co se ode mne očekává. Měl(a) jsem možnost položit jakýkoliv dotaz, týkající se použité metody i účelu této studie a potvrzuji, že všechny mé dotazy byly zodpovězeny.
3. Souhlasím, že budu plně spolupracovat s lékaři studie a budu je ihned informovat, pokud se objeví změny mého zdravotního stavu nebo nečekané či neobvyklé projevy.
4. Vím, že mohu kdykoli svobodně ze studie odstoupit, aniž by to mělo vliv na kvalitu mého dalšího léčení.
5. Chápu, že informace v mé zdravotnické dokumentaci jsou významné pro vyhodnocení výsledků studie. Souhlasím s využitím těchto informací s vědomím, že bude zachována důvěrnost těchto informací.

Koordinátor studie: PhDr. Kamila Řasová, Ph.D., kamila.rasova@gmail.com, 604511416

Podpis pacienta: „Souhlasím“

Jméno pacienta:

Datum:

Já, níže podepsaný (klinický pracovník), tímto prohlašuji, že jsem dle mého nejlepšího vědomí vysvětlil/a cíle, postupy, výhody a rovněž také rizika a diskomfort vyplývající z této studie účastníku této studie nebo jeho zákonnému zástupci (jméno a příjmení)..... Účastník poskytl svůj informovaný souhlas k účasti ve studii. Kopie informovaného souhlasu bude dobrovolníkovi poskytnuta.

Datum:

Podpis výzkumného pracovníka:

Příloha C

Obsah přiloženého CD

CD obsahuje zdrojový kód s funkcemi, které byly použity ke zpracování dat, společně s výsledky všech klasifikací dvojic parametrů ve formě dvou Excel tabulek. Tabulky obsahují vždy pro daný klasifikační model názvy dvou parametrů a střední hodnoty (mean) se směrodatnými odchylkami (std) jednotlivých hodnotících kritérií ACC, SEN a SPE. Všechny hodnoty hodnotících kritérií v daných tabulkách mají bezrozměrné jednotky, po vynásobení 100 nabývají hodnoty jednotky procent. Názvy parametrů v tabulkách jsou složené z označení signálu (acc/gyro) a měření (R/L, Open/Closed), ze kterého jsou vypočítané, a názvu daného parametru. Ukázka tabulkového názvu parametru PSD_{max} RC z dat akcelerometru: `acc_RCclosed_PSDmax`.

Soubory:

`zdrojovy_kod.mlx`

- Zdrojový kód psaný v programu MATLAB R2023b ve formě Live Script.

`klasifikace_dvojice_akcelerometr.xlsx`

- Excel tabulka s výsledky klasifikací dvojic parametrů signálů akcelerometru.

`klasifikace_dvojice_gyroskop.xlsx`

- Excel tabulka s výsledky klasifikací dvojic parametrů signálů gyroskopu.

Příloha D

Statistický popis parametrů

Tabulka D.1: Statistický popis se střední hodnotou μ a směrodatnou odchylkou σ všech vypočítaných parametrů z dat akcelerometru a gyroskopu.

Parametr	Typ měření	Akcelerometr		Gyroskop	
		Skupina s RS $\mu \pm \sigma$	Kontrolní skupina $\mu \pm \sigma$	Skupina s RS $\mu \pm \sigma$	Kontrolní skupina $\mu \pm \sigma$
f_{max} [Hz]	Pravá HK otevřené oči	4.22 \pm 2.91	5.25 \pm 3.82	1.20 \pm 0.22	1.80 \pm 2.59
	Levá HK otevřené oči	4.22 \pm 2.92	4.90 \pm 3.22	1.39 \pm 0.73	1.48 \pm 0.64
	Pravá HK zavřené oči	3.32 \pm 2.45	5.23 \pm 3.40	1.78 \pm 1.02	1.45 \pm 0.55
	Levá HK zavřené oči	3.17 \pm 2.20	3.82 \pm 3.07	1.42 \pm 0.70	1.48 \pm 0.47
PSD_{max} [dB · Hz $^{-1}$]	Pravá HK otevřené oči	-37.54 \pm 7.02	-43.50 \pm 3.32	1.60 \pm 9.82	-6.76 \pm 4.52
	Levá HK otevřené oči	-37.68 \pm 5.94	-44.18 \pm 3.40	3.83 \pm 8.80	-7.92 \pm 3.23
	Pravá HK zavřené oči	-37.21 \pm 7.40	-43.74 \pm 2.64	0.82 \pm 7.10	-7.78 \pm 3.51
	Levá HK zavřené oči	-35.81 \pm 8.54	-43.16 \pm 2.94	1.49 \pm 10.24	-7.46 \pm 3.22
PSD_{7Hz} [dB · Hz $^{-1}$]	Pravá HK otevřené oči	-42.97 \pm 7.03	-46.90 \pm 3.71	-4.95 \pm 7.24	-12.54 \pm 2.64
	Levá HK otevřené oči	-43.14 \pm 6.28	-47.71 \pm 4.09	-3.05 \pm 7.89	-12.45 \pm 2.83
	Pravá HK zavřené oči	-44.00 \pm 3.06	-47.30 \pm 3.38	-4.99 \pm 5.71	-13.26 \pm 2.40
	Levá HK zavřené oči	-42.87 \pm 5.72	-47.05 \pm 3.46	-4.65 \pm 7.70	-11.68 \pm 2.95
PSD_{0-4Hz} [dB]	Pravá HK otevřené oči	-36.53 \pm 4.48	-41.12 \pm 2.12	5.60 \pm 9.38	-3.07 \pm 3.48
	Levá HK otevřené oči	-35.30 \pm 5.43	-41.56 \pm 3.00	7.61 \pm 8.77	-3.71 \pm 2.99
	Pravá HK zavřené oči	-34.44 \pm 6.92	-41.41 \pm 2.19	4.75 \pm 6.55	-3.58 \pm 3.22
	Levá HK zavřené oči	-33.21 \pm 8.01	-40.71 \pm 2.39	5.81 \pm 9.98	-3.09 \pm 3.03
RMS [g]/[stupně · s $^{-1}$]	Pravá HK otevřené oči	0.03 \pm 0.28	0.02 \pm 0.01	4.31 \pm 4.25	1.33 \pm 0.75
	Levá HK otevřené oči	0.03 \pm 0.02	0.02 \pm 0.00	5.06 \pm 4.52	1.14 \pm 0.36
	Pravá HK zavřené oči	0.04 \pm 0.04	0.02 \pm 0.01	3.09 \pm 2.15	1.11 \pm 0.38
	Levá HK zavřené oči	0.05 \pm 0.05	0.02 \pm 0.01	4.44 \pm 4.66	1.18 \pm 0.37
$P-P$ [g]/[stupně · s $^{-1}$]	Pravá HK otevřené oči	0.36 \pm 0.28	0.19 \pm 0.08	68.05 \pm 71.50	23.00 \pm 22.59
	Levá HK otevřené oči	0.40 \pm 0.25	0.16 \pm 0.06	82.83 \pm 71.67	19.15 \pm 8.80
	Pravá HK zavřené oči	0.34 \pm 0.24	0.17 \pm 0.13	54.33 \pm 40.45	20.06 \pm 10.60
	Levá HK zavřené oči	0.47 \pm 0.40	0.17 \pm 0.07	71.78 \pm 74.03	18.66 \pm 8.74
CF [-]	Pravá HK otevřené oči	5.86 \pm 2.24	6.10 \pm 2.07	12.15 \pm 3.51	11.49 \pm 5.25
	Levá HK otevřené oči	6.73 \pm 1.96	5.57 \pm 1.47	12.76 \pm 3.63	12.19 \pm 4.94
	Pravá HK zavřené oči	6.09 \pm 2.22	5.43 \pm 2.06	14.09 \pm 5.27	13.21 \pm 4.37
	Levá HK zavřené oči	6.13 \pm 2.33	5.22 \pm 1.03	11.37 \pm 3.54	12.28 \pm 5.33
$ApEn$ [-]	Pravá HK otevřené oči	0.83 \pm 0.16	0.96 \pm 0.07	0.84 \pm 0.25	0.97 \pm 0.20
	Levá HK otevřené oči	0.83 \pm 0.14	0.95 \pm 0.06	0.75 \pm 0.22	0.98 \pm 0.13
	Pravá HK zavřené oči	0.82 \pm 0.14	0.95 \pm 0.09	0.82 \pm 0.19	0.97 \pm 0.13
	Levá HK zavřené oči	0.79 \pm 0.16	0.96 \pm 0.08	0.84 \pm 0.24	1.00 \pm 0.12
CD [-]	Pravá HK otevřené oči	1.97 \pm 0.07	1.97 \pm 0.08	1.97 \pm 0.07	2.00 \pm 0.07
	Levá HK otevřené oči	1.97 \pm 0.06	1.99 \pm 0.06	1.99 \pm 0.06	1.99 \pm 0.05
	Pravá HK zavřené oči	2.00 \pm 0.06	1.97 \pm 0.08	1.99 \pm 0.05	2.03 \pm 0.07
	Levá HK zavřené oči	2.00 \pm 0.08	1.98 \pm 0.07	1.97 \pm 0.05	1.97 \pm 0.07

Příloha E

Výsledky testu normality

Tabulka E.1: Výsledné *p-hodnoty* testu ověření rozložení dat všech parametrů vypočítaných ze signálu akcelerometru a gyroskopu.

		Akcelerometr		Gyroskop	
Parametr	Typ měření	Skupina s RS	Kontrolní skupina p-hodnota [-]	Skupina s RS	Kontrolní skupina p-hodnota [-]
f_{max}	Pravá HK otevřené oči	0.001	0.001	0.001	<0.001
	Levá HK otevřené oči	0.001	0.001	0.001	0.001
	Pravá HK zavřené oči	<0.001	0.02	0.004	0.04
	Levá HK zavřené oči	<0.001	<0.001	<0.001	0.004
PSD_{max}	Pravá HK otevřené oči	0.44	0.001	0.23	0.09
	Levá HK otevřené oči	0.38	0.01	0.38	0.32
	Pravá HK zavřené oči	0.06	0.01	0.68	0.20
	Levá HK zavřené oči	0.12	0.55	0.41	0.48
PSD_{7Hz}	Pravá HK otevřené oči	0.02	0.15	0.74	0.30
	Levá HK otevřené oči	0.20	0.06	0.22	0.83
	Pravá HK zavřené oči	0.97	0.55	0.87	0.88
	Levá HK zavřené oči	0.47	0.59	0.74	0.23
PSD_{0-4Hz}	Pravá HK otevřené oči	0.37	0.38	0.19	0.43
	Levá HK otevřené oči	0.24	0.003	0.36	0.23
	Pravá HK zavřené oči	0.08	0.43	0.45	0.56
	Levá HK zavřené oči	0.16	0.23	0.56	0.57
RMS	Pravá HK otevřené oči	<0.001	0.001	0.001	0.002
	Levá HK otevřené oči	0.09	0.29	0.006	0.38
	Pravá HK zavřené oči	<0.001	0.03	0.008	0.18
	Levá HK zavřené oči	<0.001	0.16	0.002	0.53
$P-P$	Pravá HK otevřené oči	0.01	0.06	0.002	<0.001
	Levá HK otevřené oči	0.21	0.01	0.007	0.42
	Pravá HK zavřené oči	0.002	<0.001	0.006	0.002
	Levá HK zavřené oči	0.005	0.05	0.009	0.23
CF	Pravá HK otevřené oči	0.001	0.03	0.17	0.01
	Levá HK otevřené oči	0.08	0.02	0.10	0.10
	Pravá HK zavřené oči	0.21	<0.001	0.07	0.66
	Levá HK zavřené oči	0.144	0.59	0.54	0.49
$ApEn$	Pravá HK otevřené oči	0.25	0.02	0.08	0.006
	Levá HK otevřené oči	0.13	0.54	0.10	0.86
	Pravá HK zavřené oči	0.26	0.17	0.52	0.34
	Levá HK zavřené oči	0.23	0.94	0.43	0.20
CD	Pravá HK otevřené oči	0.93	0.18	0.06	0.01
	Levá HK otevřené oči	0.89	0.26	0.44	0.23
	Pravá HK zavřené oči	0.99	0.11	0.98	0.41
	Levá HK zavřené oči	0.24	0.99	0.96	0.31

Příloha F

Statisticky významné parametry

Tabulka F.1: Výsledné *p-hodnoty* a hodnoty *statistiky* daného testu statisticky významných rozdílů mezi skupinami zdravý/nemocný těch parametrů, které měly výslednou *p-hodnotou* nižší než $\alpha = 0.01$. Tyto parametry byly použity k následné klasifikaci dat.

Akcelerometr			
Parametr	Typ měření	p hodnota [-]	statistika [-]
PSD_{max}	Pravá HK otevřené oči	0.005	361
	Pravá HK zavřené oči	0.002	369
	Levá HK otevřené oči	0.002	369
	Levá HK zavřené oči	0.002	3.43
$P-P$	Pravá HK zavřené oči	0.001	377
	Levá HK otevřené oči	0.002	369
	Levá HK zavřené oči	0.005	361
PSD_{7Hz}	Pravá HK zavřené oči	0.006	2.97
PSD_{0-4Hz}	Levá HK otevřené oči	0.001	370
	Pravá HK zavřené oči	<0.001	4.06
	Levá HK zavřené oči	0.001	3.79
	Pravá HK otevřené oči	<0.001	3.90
RMS	Levá HK zavřené oči	0.002	369
	Levá HK otevřené oči	0.001	3.62
	Pravá HK zavřené oči	0.001	379
$ApEn$	Levá HK otevřené oči	0.002	-3.44
	Pravá HK zavřené oči	0.002	-3.44
	Levá HK zavřené oči	0.001	-3.78
Gyroskop			
Parametr	Typ měření	p hodnota [-]	statistika [-]
RMS	Pravá HK zavřené oči	<0.001	391
	Levá HK otevřené oči	<0.001	389
	Levá HK zavřené oči	0.004	363
	Pravá HK otevřené oči	0.005	362
$P-P$	Levá HK otevřené oči	<0.001	384
	Pravá HK zavřené oči	0.001	379
	Pravá HK otevřené oči	0.005	361
PSD_{7Hz}	Pravá HK zavřené oči	<0.001	5.62
	Levá HK otevřené oči	<0.001	4.73
	Pravá HK otevřené oči	<0.001	4.15
	Levá HK zavřené oči	0.001	3.59
PSD_{max}	Levá HK otevřené oči	<0.001	5.29
	Pravá HK zavřené oči	<0.001	4.56
	Levá HK zavřené oči	0.001	3.52
	Pravá HK otevřené oči	0.003	3.25
PSD_{0-4Hz}	Levá HK otevřené oči	<0.001	5.16
	Pravá HK zavřené oči	<0.001	4.79
	Pravá HK otevřené oči	0.001	3.66
	Levá HK zavřené oči	0.001	3.61
$ApEn$	Pravá HK zavřené oči	0.008	-2.83
	Levá HK otevřené oči	0.001	-3.76

Příloha G

Prvních pět klasifikačních dvojic parametrů s nejlepšími výsledky

Tabulka G.1: Prvních pět dvojic parametrů dat akcelerometru a gyroskopu K-means klasifikace s použitím Euklidovské a Manhattanské vzdálenosti s výslednými hodnotícími kritérii.

Akcelerometr			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Vzdálenost	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{0-4Hz} LO	PSD_{0-4Hz} RC	Euklidovská	82.38 ± 11.86	68.33 ± 20.75	100 ± 0
PSD_{7Hz}	$ApEn$ LC	Euklidovská	82.38 ± 6.21	65 ± 13.69	93.33 ± 14.91
PSD_{7Hz} LO	PSD_{7Hz} RC	Euklidovská	81.90 ± 16.63	73.33 ± 25.28	95 ± 11.18
PSD_{max} LO	PSD_{0-4Hz} RC	Euklidovská	81.90 ± 19.46	68 ± 29.50	100 ± 0
PSD_{max} RC	PSD_{0-4Hz} RC	Euklidovská	80 ± 23.90	64 ± 37	100 ± 0
PSD_{max} LO	PSD_{0-4Hz} RC	Manhattanská	82.86 ± 11.95	60.95 ± 25.68	80 ± 44.72
PSD_{0-4Hz} LC	$ApEn$ LO	Manhattanská	82.68 ± 11.86	62 ± 21.68	100 ± 0
PSD_{0-4Hz} LO	PSD_{0-4Hz} RC	Manhattanská	81.90 ± 16.63	66.67 ± 31.18	100 ± 0
$P-P$ LO	PSD_{0-4Hz} RC	Manhattanská	81.90 ± 13.21	56.67 ± 27.89	100 ± 0
PSD_{max} LO	PSD_{0-4Hz} LC	Manhattanská	81.43 ± 21.19	70.33 ± 31.37	100 ± 0
Gyroskop			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Vzdálenost	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{7Hz} RC	PSD_{max} LO	Euklidovská	85.24 ± 10.16	70 ± 24.01	100 ± 0
PSD_{7Hz} RC	PSD_{0-4Hz} LO	Euklidovská	85.24 ± 14.33	63.33 ± 41.50	100 ± 0
PSD_{7Hz} RC	$ApEn$ LO	Euklidovská	84.76 ± 11.86	67.67 ± 26.18	100 ± 0
PSD_{7Hz} RC	PSD_{max} RC	Euklidovská	82.38 ± 11.86	68.33 ± 20.75	100 ± 0
PSD_{0-4Hz} RC	PSD_{0-4Hz} LC	Euklidovská	81.90 ± 19.46	51.67 ± 45.80	100 ± 0
PSD_{7Hz} RC	$ApEn$ LO	Manhattanská	85.71 ± 14.29	76.67 ± 32.49	93.33 ± 14.91
PSD_{7Hz} RC	PSD_{max} LO	Manhattanská	85.24 ± 17.53	73.33 ± 25.18	100 ± 0
PSD_{7Hz} RC	PSD_{max} LC	Manhattanská	82.86 ± 23.47	63.33 ± 41.50	100 ± 0
PSD_{0-4Hz} RC	PSD_{7Hz} RO	Manhattanská	82.86 ± 11.95	66.67 ± 20.41	100 ± 0
$P-P$ RC	PSD_{7Hz} RC	Manhattanská	82.38 ± 15.58	63.00 ± 24.39	100 ± 0

Tabulka G.2: Prvních pět dvojic parametrů dat akcelerometru a gyroskopu K-NN klasifikace s použitím tří a pěti nejbližších sousedů s výslednými hodnotícími kritérii.

Akcelerometr					
Parametr 1	Parametr 2	Počet sousedů	ACC [%]	SEN [%]	SPE [%]
			$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{7Hz} RC	$ApEn$ LO	3	85.70 ± 20.20	78.67 ± 30.70	90 ± 22.36
PSD_{0-4Hz} RO	PSD_{0-4Hz} LC	3	85.24 ± 10.16	58.33 ± 37.27	100 ± 0
PSD_{max} RO	P-P LC	3	82.86 ± 11.95	79.33 ± 21.65	91 ± 12.45
RMS RC	P-P RC	3	82.38 ± 6.21	84.29 ± 22.81	67 ± 38.67
PSD_{0-4Hz} LO	PSD_{0-4Hz} RO	3	82.38 ± 6.21	60 ± 18.07	100 ± 0
RMS LC	PSD_{0-4Hz} LC	5	82.86 ± 11.95	75.33 ± 23.29	96 ± 8.94
PSD_{0-4Hz} LO	PSD_{0-4Hz} LC	5	82.86 ± 18.63	64.29 ± 41.65	80 ± 44.72
RMS RC	PSD_{0-4Hz} LO	5	82.38 ± 15.58	53.33 ± 40.23	100 ± 0
RMS RC	PSD_{max} LC	5	79.52 ± 16.11	69.33 ± 21.27	82 ± 24.90
PSD_{0-4Hz} LO	P-P LO	5	79.52 ± 16.11	58.33 ± 27.64	100 ± 0
Gyroskop					
Parametr 1	Parametr 2	Počet sousedů	ACC [%]	SEN [%]	SPE [%]
			$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
RMS RC	PSD_{0-4Hz} LC	3	88.57 ± 11.95	73.33 ± 25.28	100 ± 0
RMS LO	P-P RC	3	88.57 ± 11.95	81.67 ± 20.75	96 ± 8.94
P-P LO	P-P RC	3	88.57 ± 11.95	81.67 ± 20.75	96 ± 8.94
PSD_{7Hz} RC	$ApEn$ LO	3	88.57 ± 11.95	76.67 ± 43.46	96 ± 8.94
P-P LO	PSD_{7Hz} RC	3	85.71 ± 14.29	73.33 ± 43.46	96 ± 8.94
RMS LO	P-P RC	5	88.57 ± 11.95	81.67 ± 20.75	96 ± 8.94
P-P LO	P-P RC	5	88.57 ± 11.95	81.67 ± 20.75	96 ± 8.94
RMS LC	PSD_{7Hz} RC	5	88.57 ± 15.65	73.33 ± 43.46	100 ± 0
P-P LO	PSD_{7Hz} RC	5	85.71 ± 14.29	73.33 ± 43.46	96 ± 8.94
P-P RC	PSD_{max} LO	5	85.71 ± 17.50	71.67 ± 41.50	96 ± 8.94

Tabulka G.3: Prvních pět dvojic parametrů dat akcelerometru a gyroskopu SVM klasifikace s použitím přístupu tvrdého SVM a Soft margin s výslednými hodnotícími kritérii.

Akcelerometr					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Přístup	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{0-4Hz} LO	$ApEn$ RC	tvrdé SVM	82.38 ± 6.21	70 ± 24.01	95 ± 11.18
RMS LC	PSD_{0-4Hz} RC	tvrdé SVM	82.38 ± 11.86	56 ± 37.82	100 ± 0
PSD_{0-4Hz} LO	PSD_{7Hz} RC	tvrdé SVM	81.90 ± 13.21	73.33 ± 27.89	96.67 ± 7.45
PSD_{0-4Hz} RC	PSD_{0-4Hz} LC	tvrdé SVM	81.90 ± 13.21	63.33 ± 24.72	100 ± 0
PSD_{0-4Hz} RC	PSD_{max} LC	tvrdé SVM	81.43 ± 18.63	58.33 ± 44.88	95 ± 11.18
PSD_{0-4Hz} RC	PSD_{0-4Hz} LC	Soft margin	82.38 ± 15.58	51 ± 40.37	100 ± 0
PSD_{0-4Hz} LO	$ApEn$ RC	Soft margin	82.38 ± 6.21	66 ± 10.65	95 ± 11.18
RMS RC	PSD_{0-4Hz} LO	Soft margin	80 ± 16.29	65 ± 35.55	96 ± 8.94
RMS RC	PSD_{max} RC	Soft margin	80 ± 19.17	60 ± 43.46	96 ± 8.94
RMS LC	PSD_{0-4Hz} RC	Soft margin	80 ± 16.29	65.33 ± 20.63	93.33 ± 14.91
Gyroskop					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Přístup	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
$P-P$ LO	PSD_{7Hz} RC	tvrdé SVM	90.91 ± 8.32	70 ± 41.08	100 ± 0
RMS LC	PSD_{7Hz} RC	tvrdé SVM	90.91 ± 8.32	76.67 ± 22.36	100 ± 0
RMS RC	PSD_{max} LO	tvrdé SVM	88.57 ± 11.95	78.33 ± 21.73	100 ± 0
RMS RC	PSD_{0-4Hz} LO	tvrdé SVM	88.57 ± 6.39	75 ± 14.43	100 ± 0
$P-P$ RC	PSD_{max} LO	tvrdé SVM	88.57 ± 11.95	83.33 ± 23.57	96.67 ± 7.45
PSD_{7Hz} RC	PSD_{0-4Hz} LO	Soft margin	91.43 ± 12.78	83.33 ± 23.57	100 ± 0
RMS RC	PSD_{max} LO	Soft margin	88.57 ± 11.95	77 ± 22.80	100 ± 0
$P-P$ LO	PSD_{7Hz} RC	Soft margin	88.57 ± 18.63	85 ± 22.36	100 ± 0
RMS LO	PSD_{7Hz} RC	Soft margin	88.10 ± 6.73	63.33 ± 37.55	91.14 ± 6.39
PSD_{7Hz} RC	PSD_{max} LO	Soft margin	88.10 ± 6.73	81.67 ± 17.08	96 ± 8.94

Tabulka G.4: Prvních pět dvojic parametrů dat akcelerometru a gyroskopu Naivní Bayesovy klasifikace s výslednými hodnotícími kritérii.

Akcelerometr					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{7Hz} RC	$ApEn$ LO	82.86 ± 18.63	68.33 ± 33.54	95 ± 11.18	
$P-P$ LO	$ApEn$ LC	82.86 ± 23.47	65 ± 48.73	96 ± 8.94	
PSD_{0-4Hz} LC	$ApEn$ RC	82.38 ± 11.86	70 ± 20.92	93.33 ± 14.91	
$P-P$ LO	$ApEn$ RC	82.38 ± 6.21	67.67 ± 26.18	95 ± 11.18	
PSD_{0-4Hz} RC	RMS LO	82.38 ± 6.21	64.33 ± 13.92	95 ± 11.18	
Gyroskop					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
$P-P$ LO	PSD_{7Hz} RC	91.43 ± 12.78	82.67 ± 28.91	100 ± 0	
RMS LO	PSD_{7Hz} RC	90.95 ± 13.08	76.67 ± 32.49	100 ± 0	
PSD_{max} LO	$ApEn$ LO	90.95 ± 13.08	80 ± 29.81	100 ± 0	
RMS LO	$P-P$ RC	88.57 ± 11.95	82 ± 24.90	95 ± 11.18	
RMS LO	PSD_{max} RC	88.57 ± 18.63	78 ± 30.33	100 ± 0	

Příloha H

Hodnocení klasifikací trojic vytvořených ze tří nejčetnějších parametrů prvních 15 dvojic dané klasifikační metody

Tabulka H.1: Trojice parametrů vytvořené ze tří nejčetnějších parametrů prvních 15 dvojic s výslednými hodnotícími kritérii SVM klasifikace.

Akcelerometr					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Parametr 3	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{0-4Hz} LC	RMS LC	PSD_{0-4Hz} RC	81.90 ± 13.21	66 ± 25.86	100 ± 0
PSD_{0-4Hz} LC	PSD_{0-4Hz} LO	PSD_{0-4Hz} RC	79.05 ± 13.72	61.67 ± 28.63	93.33 ± 14.91
RMS LC	PSD_{0-4Hz} LO	PSD_{0-4Hz} RC	79.05 ± 17.04	70 ± 32.60	96 ± 8.94
PSD_{0-4Hz} LC	RMS LC	PSD_{0-4Hz} LO	76.19 ± 13.47	49.67 ± 30.74	96 ± 8.94
Gyroskop					
			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Parametr 3	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{0-4Hz} LO	PSD_{max} LO	PSD_{7Hz} RC	88.10 ± 12.14	81.67 ± 29.11	93.33 ± 14.91
PSD_{max} LO	PSD_{7Hz} RC	RMS RC	88.10 ± 6.73	82.67 ± 16.73	93.33 ± 14.91
PSD_{0-4Hz} LO	PSD_{7Hz} RC	RMS RC	85.24 ± 14.33	67 ± 41.17	100 ± 0
PSD_{0-4Hz} LO	PSD_{max} LO	RMS RC	82.86 ± 15.65	71 ± 21.33	92 ± 17.89

Tabulka H.2: Trojice parametrů vytvořené ze tří nejčetnějších parametrů prvních 15 dvojic s výslednými hodnotícími kritérii Naivní Bayesovy klasifikace.

Akcelerometr			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Parametr 3	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
$ApEn$ LC	$P\text{-}P$ LO	$ApEn$ RC	81.90 ± 16.63	78 ± 25	93.33 ± 14.91
$ApEn$ LO	$P\text{-}P$ LO	$ApEn$ RC	80 ± 19.17	68.33 ± 32.49	95 ± 11.18
$ApEn$ LO	$ApEn$ RC	$PSD_{0\text{-}4Hz}$ RC	80 ± 12.78	65.33 ± 20.63	95 ± 11.18
$ApEn$ LC	$ApEn$ LO	$P\text{-}P$ LO	79.52 ± 16.11	70 ± 28.28	96.67 ± 7.45
$ApEn$ LC	$ApEn$ RC	$PSD_{0\text{-}4Hz}$ RC	79.52 ± 12.55	60 ± 25.28	96 ± 8.94
$ApEn$ LO	$P\text{-}P$ LO	$PSD_{0\text{-}4Hz}$ RC	79.05 ± 13.72	56 ± 37.82	96 ± 8.94
$P\text{-}P$ LO	$ApEn$ RC	$PSD_{0\text{-}4Hz}$ RC	79.05 ± 9.28	67.67 ± 26.18	92 ± 17.89
$ApEn$ LC	$ApEn$ LO	$PSD_{0\text{-}4Hz}$ RC	79.05 ± 24.42	67.33 ± 34.19	93.33 ± 14.91
$ApEn$ LC	$P\text{-}P$ LO	$PSD_{0\text{-}4Hz}$ RC	79.05 ± 17.04	61.67 ± 27.39	93.33 ± 14.91
$ApEn$ LC	$ApEn$ LO	$ApEn$ RC	78.57 ± 18.90	65 ± 41.83	96 ± 8.94
Gyroskop			ACC [%]	SEN [%]	SPE [%]
Parametr 1	Parametr 2	Parametr 3	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
PSD_{max} LC	$PSD_{0\text{-}4Hz}$ LO	PSD_{max} LO	88.57 ± 11.95	75 ± 27.64	100 ± 0
$PSD_{0\text{-}4Hz}$ LO	RMS LO	PSD_{7Hz} RC	88.57 ± 11.95	80 ± 18.26	100 ± 0
PSD_{max} LC	RMS LO	PSD_{7Hz} RC	88.10 ± 18.75	80 ± 27.39	100 ± 0
PSD_{max} LO	RMS LO	PSD_{7Hz} RC	88.10 ± 6.73	63.33 ± 37.55	100 ± 0
PSD_{max} LC	$PSD_{0\text{-}4Hz}$ LO	PSD_{7Hz} RC	87.62 ± 13.72	80 ± 29.81	95 ± 11.18
PSD_{max} LC	PSD_{max} LO	PSD_{7Hz} RC	87.62 ± 17.04	82 ± 24.90	96 ± 8.94
PSD_{max} LC	PSD_{max} LO	RMS LO	85.71 ± 14.29	72.67 ± 30.04	100 ± 0
$PSD_{0\text{-}4Hz}$ LO	PSD_{max} LO	RMS LO	85.24 ± 10.16	60.33 ± 36.98	100 ± 0
$PSD_{0\text{-}4Hz}$ LO	PSD_{max} LO	PSD_{7Hz} RC	85.24 ± 10.16	83.33 ± 15.59	86.67 ± 18.26
PSD_{max} LC	$PSD_{0\text{-}4Hz}$ LO	RMS LO	84.76 ± 15.58	63.33 ± 34.16	100 ± 0