

**UNIVERZITA KARLOVA**

**Lékařská fakulta v Hradci Králové**

# **DISERTAČNÍ PRÁCE**

Doktorský studijní program

**Neurologie**

## **Objektivní sledování vývoje hybných poruch pomocí senzorů**

### **Sensor-based objective assessment of motion disorders**

**MUDr. Ondřej Dostál**

Školitel: MUDr. Oldřich Vyšata, Ph.D.

Hradec Králové, 2021

## **Prohlášení autora**

### **Prohlášení:**

Prohlašuji tímto, že jsem doktorskou disertační práci zpracoval/a samostatně a že jsem uvedl/a všechny použité informační zdroje. Zároveň dávám souhlas k tomu, aby tato práce byla uložena v Lékařské knihovně Lékařské fakulty v Hradci Králové a zde užívána ke studijním účelům za předpokladu, že každý, kdo tuto práci použije pro svou publikační nebo přednáškovou činnost, se zavazuje, že bude tento zdroj informací řádně citovat.

Souhlasím se zpřístupněním elektronické verze mé práce v informačním systému Univerzity Karlovy, Praha.

**Hradec Králové, 2021**

**Ondřej Dostál**

.....

**podpis autora**

## **Poděkování**

V první řadě bych rád poděkoval svému školiteli MUDr. Oldřichu Vyšatovi, Ph.D. za seznámení mě s prostředím výzkumu již v době studií na vysoké škole, za spoustu konzultačních hodin a vlídnou pomoc v průběhu celé vědecké činnosti.

Velké poděkování patří také profesoru Ing. Aleši Procházkovi, CSc. a Ing. Ondřeji Ťupovi, Ph.D. za vynikající spolupráci a velkou pomoc při analýze dat a publikaci výsledků.

Dále bych chtěl poděkovat profesoru MUDr. Martinu Vališovi, Ph.D., FEAN, Fakultní nemocnici Hradec Králové a Lékařské fakultě Univerzity Karlovy za zajištění veškerých podmínek pro potřeby výzkumu.

Nakonec děkuji své ženě za její trpělivou podporu.

# Obsah

<b>Prohlášení autora</b> .....	<b>1</b>
<b>Poděkování</b> .....	<b>2</b>
<b>Obsah</b> .....	<b>3</b>
<b>Seznam použitých zkratk</b> .....	<b>5</b>
<b>Souhrn</b> .....	<b>6</b>
<b>Úvod do problematiky</b> .....	<b>7</b>
Současný zdravotní systém a jeho udržitelnost.....	7
Stručná historie kinematické analýzy.....	7
Personalizovaná a precizní medicína.....	8
Potřeba objektivního vyšetření pohybové aktivity.....	9
<b>Klinické škály</b> .....	<b>11</b>
1. Spasticita.....	11
2. Denní aktivity.....	11
3. Funkce horní končetiny.....	12
4. Chůze.....	12
5. Komplexní pohybové škály, celkový stav.....	12
<b>Zařízení k analýze lidského pohybu</b> .....	<b>14</b>
1. Akcelerometry.....	14
2. Gyroskopická čidla.....	15
3. Magnetometry.....	15
4. Inerciální měřící jednotky (IMU).....	15
5. Goniometry a torsiometry.....	16
6. Nositelné (wearable) povrchové EMG.....	16
7. Optoelektronická zařízení.....	16
8. Tlakové senzory.....	17
a. Tlakové podložky.....	17
b. Vložky do bot.....	17
9. Aktigrafická čidla.....	17
10. Další možnosti sledování pohybové aktivity.....	18
<b>Předzpracování dat</b> .....	<b>19</b>
<b>Parametrizace dat</b> .....	<b>20</b>
1. Analýza chůze.....	20
2. Analýza stoje.....	23
3. Analýza pohybu končetin.....	23
<b>Balancování parametrů a normalizace dat</b> .....	<b>25</b>
<b>Redukce dimenzionality</b> .....	<b>26</b>
<b>Metody strojového učení (machine learning)</b> .....	<b>28</b>
1. Logistická regrese.....	28
2. Support Vector Machine (SVM).....	28
3. Naive Bayes.....	29
4. K-Nearest Neighbor (k-NN).....	29
5. Decision Tree.....	29
6. Random Forest.....	29
7. Neuronová síť (Neural network, NN).....	30
8. Adaptive Boosting (AdaBoost).....	30
9. Majority Voting.....	30
<b>Evaluační účinnosti metod strojového učení</b> .....	<b>31</b>

<b>Aplikace v klinické praxi.....</b>	<b>33</b>
1. Parkinsonova choroba (PD).....	33
2. Cévní mozkové příhody (CMP).....	33
3. Alzheimerova nemoc (AD).....	34
4. Roztroušená skleróza (RS).....	34
5. Poruchy spánku.....	35
6. Další uplatnění.....	36
<b>Současné problémy v analýze pomocí senzorů.....</b>	<b>37</b>
<b>Cíl disertační práce.....</b>	<b>39</b>
<b>Metody.....</b>	<b>40</b>
Část první.....	40
Část druhá.....	40
Část třetí.....	41
<b>Sběr dat.....</b>	<b>42</b>
<b>Soubor jedinců.....</b>	<b>45</b>
<b>Parametrizace signálu.....</b>	<b>47</b>
<b>Normalizace dat, balancování tříd a redukce dimenzionality.....</b>	<b>49</b>
<b>Klasifikace.....</b>	<b>50</b>
<b>Výsledky.....</b>	<b>52</b>
Část první.....	52
Část druhá.....	56
Část třetí.....	60
<b>Diskuze.....</b>	<b>68</b>
<b>Závěr.....</b>	<b>70</b>
<b>Autorovi práce k tématu.....</b>	<b>72</b>
<b>Zdroje literatury.....</b>	<b>75</b>

## **Seznam použitých zkratk**

MOCAP – motion capture device

SARA – Scale for the Assessment and Rating of Ataxia

MEMS – mikro-elektrické mechanické systémy

SD – směrodatná odchylka

FT – Fourierova transformace

SMOTE – Synthetic Minority Oversampling Technique

PCA – Principal Component Analysis

TSNE – t-distributed stochastic neighbor embedding

SVM – support vector machine

NN – neural net, neuronová síť

k-NN – k nearest neighbours

IMU – inerciální měřící jednotka

## **Souhrn**

Problémem současného výzkumu v oblasti vývoje a léčby hybných poruch v neurologii a rehabilitaci je nízká reprodukovatelnost klinických škál pro vysokou intra- a interindividuální variabilitu. Možností řešení je využití nízkoenergetických biosenzorů, které umožní časnou diagnostiku, kontinuální monitoraci efektu terapie a rychlou reakci na náhlé zhoršení stavu. Dlouhodobé sledování jedince v přirozeném prostředí přináší alternativu k současnému způsobu pozorování, které je omezené na jednorázové vyšetření v nepřirozených podmínkách zdravotnického zařízení. Výhodou je možnost odhalení skrytých závislostí měřených veličin, objektivizace fungování v běžných denních aktivitách a následná optimalizace léčby. Kombinace vícečetných parametrů v reálném čase umožňuje přesnější modelování lidského pohybu a jeho poruch v přirozeném prostředí. Eliminuje se vliv mezilidské interakce na sledované veličiny a variability mezi hodnotiteli, což vede k objektivizaci měření. Práce obsahuje přehled aktuálních možností sledování pohybové aktivity, zpracování získaných dat, analýzy pomocí metod strojového učení a současné možnosti uplatnění v klinické praxi.

## **Summary**

The problem of current research in the field of treatment and natural development of movement disorders in neurology and rehabilitation is the low reproducibility of clinical results due to high intra- and inter-individual variability. A possible solution is the use of low-energy biosensors with the aim of early diagnosis, continuous monitoring of therapy effect and early response to sudden deterioration. Long-term monitoring of an individual in the natural environment provides an alternative to current method of observation, which is limited to a single examination in unnatural conditions of medical facility. The advantage is the possibility of revealing hidden dependencies of measured quantities, objective view of functioning in common daily activities and subsequent optimization of treatment. The combination of multiple parameters in real time allows more accurate modeling of human movement and its impairment in natural environment. It eliminates the influence of interpersonal interactions on the observed quantities and variability among evaluators, which ensures objective measurements. The reader will find a summary of current possibilities of physical activity recording, processing of obtained data, analysis using machine learning methods and current applications in clinical practice.



## **Úvod do problematiky**

### **Současný zdravotní systém a jeho udržitelnost**

V České republice došlo mezi rokem 1989 a rokem 2019 k postupnému nárůstu počtu obyvatel starších 65 let z 12,5% na 19,9% . Obdobně se vyvíjí i demografická struktura obyvatel ostatních rozvinutých zemí. S rostoucím věkem narůstá množství zdravotních komplikací, což vede k navyšování počtu kontaktů se zdravotnickým systémem. Tento fakt reflektuje statistika nárůstu výdajů na zdravotní péči v ČR mezi roky 2010 a 2017, kde jednoznačně dominuje kategorie 70-74 let. Velikost výdajů také zvyšují rozšiřující se možnosti a počty pomocných vyšetření, které „západní“ medicína nabízí. <sup>1</sup>

Současný trend světového zdravotnictví není dlouhodobě udržitelný, a to nejen z důvodů finančních, ale i z pohledu lidských zdrojů. <sup>2</sup>

S cílem udržení kvality a dostupnosti zdravotnické péče při zachování lidského přístupu k pacientovi je nutný vývoj takových technologií, které budou snadno dostupné, nabídnou kvalitní diagnostiku a sledování nemocných a zároveň nebudou zvyšovat časové nároky na zdravotnický personál.

Jedním z možných řešení je využití nízkoenergetických biosenzorů, které umožní časnou diagnostiku, kontinuální monitoraci efektu terapie a rychlou reakci na náhlé zhoršení stavu. Technologický vývoj přináší nové možnosti z pohledu přesnosti a miniaturizace snímacích zařízení a také v oblasti výpočetních systémů a analytických metod schopných zpracovávat obrovské objemy dat. Vývoj zařízení schopných popsat komplexní biologické systémy jako je lidské tělo, je multidisciplinární výzvou pro řadu současných vědeckých týmů.

### **Stručná historie kinematické analýzy**

Pohyb je základní vlastností živočichů, umožňuje přesun z místa na místo, dýchání, kopulaci, příjem a zpracování potravy a ochranu před nebezpečím. Lidský pohyb je vysoce komplexní děj koordinovaný centrální nervovou soustavou a vykonávaný svalově-kosterním aparátem.

První dochované zmínky o snaze popsat lidský pohyb za pomoci matematických a geometrických zákonitostí jsou dochovány v textech Aristotela již ve 3. století př.n.l.<sup>3</sup>. Další detailní modely popisující lidský pohyb a jeho biomechaniku přinesla řada autorů jako DaVinci<sup>4</sup>, G. A. Borelli<sup>5</sup> a Galileo Galilei. V 18. století přispěl k pochopení pohybu objev elektrické aktivity svalové tkáně a vynález elektromyografu ve století 19. V druhé polovině 19. století využívá Etienne-Jules Marey a Eadweard Muybridge fotoaparát a sekvenční snímkování k analýze pohybu zvířat i lidské chůze a běhu.

Později je za pomoci videokamery analyzován jak fyziologický pohyb, tak jeho patologie při neurologických i ortopedických onemocněních. Dalším skokem ve vývoji kinematické analýzy sehrál rozvoj videokamer s vysokou snímkovací frekvencí, infračervených kamer a zejména výpočetní techniky, která umožnila trojrozměrné rekonstrukce pohybových aktivit.<sup>6</sup>

## **Personalizovaná a precizní medicína**

Navzdory zjevné skutečnosti, že fyziologie pacientů se u jednotlivých jedinců podstatně liší, vývoj léčiv a péče o pacienty do značné míry závisí na administraci jednotných léčebných schémat. I když některé scénáře umožňují výběr a dávkování medikace na míru podle odpovědi pacienta, neřízená titrace zůstává běžným postupem péče. Pacienti jsou tak omezeni na cílový výběr léků a protokoly podávání s definovanou eskalací dávky. Tyto konvenční způsoby léčby predisponují pacienty k suboptimální odpovědi na léčbu.<sup>7</sup>

Změnu uvažování nad přístupem k prezentovaným obtížím, interpretaci pomocných vyšetření a volbě terapie přináší koncept personalizované a precizní medicíny.

Oba termíny se značně překrývají, nicméně personalizovaná medicína zahrnuje využití technologií s cílem co nejkvalitnějšího popisu symptomů a interpretace pomocných vyšetření vč. genové sekvenace. S ohledem na získaná data a fenotyp jedince je navržena optimální léčebná strategie.

Precizní medicína rozšiřuje koncept personalizované medicíny. Pomocí technologií a umělé inteligence popisuje stav jednotlivce jako reakci na vlivy prostředí, životního stylu a genetických faktorů. Zahrnuje technologie k získání a validaci mnohazměrných populačních dat s cílem kategorizace jedinců a přiřazení vhodné terapie.

Úspěch personalizované a precizní medicíny je mimo jiné založen na technologiích umožňujících přesnou diagnostiku onemocnění a kombinaci velkých zdravotnických databází k hledání potenciálních možností terapie, identifikaci biomarkerů odrážejících chorobné stavy, neustálého sledování průběhu nemoci nebo reakce na léčbu. Konvenční přístupy k monitoraci efektu léčby zahrnují analýzu séra a moči nebo zobrazovací metody, které jsou často omezeny frekvencí testování, zvláště pokud se odpověď na léčbu mění v měřítku hodin nebo dokonce minut. Umělá inteligence spolu s nositelnými („wearable“) technologiemi jsou vhodnou kombinací k hodnocení změn fyziologie pacientů v průběhu léčby a vede ke zlepšení designu personalizovaných intervencí.<sup>8</sup>

### **Potřeba objektivního vyšetření pohybové aktivity**

Možnosti vyšetření funkčního stavu pohybové soustavy jsou v naprosté většině případů omezeny na klinické vyšetření druhou osobou či výpovědi vyšetřované osoby samotné. V obou případech se jedná o subjektivní hodnocení stavu, které je v případě klinického vyšetření zatíženo vlastní zkušeností hodnotitele. Základní klinické vyšetření není nijak standardizováno, prakticky každý vyšetřující používá svoji „osvědčenou“ baterii vyšetření, z nichž tvoří klinické závěry, často v rozporu s se závěry kolegů. Onemocnění tak nejsou diagnostikovány včas a dochází k chybným interpretacím nálezů. Přibližně 25% pacientů s diagnózou Parkinsonovy nemoci, 30% s epilepsií a více než 30% s esenciálním tremorem jsou diagnostikováni chybně<sup>9-11</sup>.

O něco lepší kvalitu stan kvantifikace postižení vykazují standardizované klinické škály. Ty jsou ale také zatíženy variabilitou mezi jednotlivými hodnotiteli i variabilitou v rámci vyšetření jednou osobou v čase. Nevýhodou současné praxe je fakt, že vyšetření jsou prováděna v nepřírodných podmínkách a jejich výsledky reprezentují pouze omezený časový úsek.<sup>10,12</sup>

Z výše uvedených důvodů narůstá poptávka po klinicky ověřených technologiích, které zajistí včasnější a přesnější diagnostiku a objektivní kvantifikaci míry postižení. Důležitým požadavkem je možnost dlouhodobé monitorace v přirozeném prostředí, která přinese konstantní analýzu symptomů, fluktuací a bude včas detekovat zhoršení průběhu onemocnění. Takové technologie musí být přenositelné, lehké, bezdrátové, vybavené algoritmy ke zpracování dat v reálném čase. Z tohoto pohledu jsou řešením nositelné („wearable“) pohybové senzory.

Pohybové senzory umožňují včasnější a přesnější diagnostiku. Objektivní sledování průběhu onemocnění, jeho léčby a případně průběhu a efektu rehabilitace <sup>13</sup>.

Nacházejí uplatnění i při monitoraci farmakologických studií <sup>14</sup>.

Při správném použití mají vyšší spolehlivost měření než klinické škály <sup>15</sup>. Měření lze provádět nezávisle na okolních podmínkách s výbornými výsledky i při nedodržení standardizovaného postupu (např. rozdílný senzor, jiné umístění senzoru, rozdílná délka a rychlost chůze).<sup>16</sup>

Přínosem je rovněž možnost detekce změn, které nejsou pozorovatelné pouhým lidským okem.<sup>17</sup>

Aplikací metod strojového učení lze odhadovat prognózu nemocných a předcházet komplikacím.

18,19

## Klinické škály

Za účelem vyšetření a kvantifikace hybných poruch existuje široká paleta klinických škál, liší se svojí komplexností, délkou provedení, nároky na vyšetřovací prostor a pomůcky. Hodnoceny mohou být jednotlivé pohybové úkony nebo schopnost vykonávat komplexnější činnosti jako jsou aktivity běžného života. Existují i škály postavené na principu dotazníku, kdy pohybový výkon hodnotí sám vyšetřovaný. Níže je uveden výběr nejčastěji využívaných škál zahrnujících hodnocení poruch hybnosti.

### 1. Spasticita

- Ashworth scale (AS) a Modified Ashworth scale (MAS): využívá se k hodnocení míry spasticity, svalového napětí a rozsahu pohybů. Testovaný sval se pasivně v průběhu jedné sekundy protáhne do maximální délky. Přitom se dosahuje úhlové rychlosti až 80°/s. Nevýhodou je právě omezení pouze na pasivní protažení svalových skupin.
- Tardieu scale: hodnotí centrální složku spasticity. Zaznamenává se reflexní odpověď (kontrakce, „catch“) v různém stupni pasivního protažení spastického svalu při různých rychlostech.

### 2. Denní aktivity

- Barthel Index: hodnotí schopnost nemocného vykonávat běžné denní činnosti. Hodnotí se jak schopnost pohybu (přemísťování, mobilita), ovládání vegetativních funkcí (močový měchýř, střeva), stanovuje se míra soběstačnosti i potřeba pomoci další osoby
- Modified Rankin Scale (mRS): je jednoduchá stupnice míry omezení v běžných denních činnostech.<sup>20</sup>
- Disability Assessment Scale: je jednoduchá škála založená na rozhovoru s pacientem. hodnotí ve 3 bodech aktivitu nemocného a ve čtvrtém bodě se posuzuje bolest a dyskomfort nemocného.<sup>21</sup>

- The Amyotrophic Lateral Sclerosis Functional Rating Scale (ALSFERS): jednoduchá subjektivní škála posuzující schopnost vykonávat běžné denní aktivity vč. chůze<sup>22</sup>

### 3. Funkce horní končetiny

- Action Research Arm Test (ARAT): posuzuje koordinaci, obratnost a funkci horní končetiny. Využívána je zejména po cévních mozkových příhodách, traumatech mozku a při roztroušené skleróze. Sleduje různé typy úchopu a schopnost přemísťovat různé objekty.<sup>23</sup>
- ABILHAND a Manual Ability Measurement (MAM) jsou dotazníky, které vyplňuje vyšetřovaný, cílí na manuální schopnost vykonávat aktivity běžného života.<sup>24</sup>
- Nine-Hole Peg test (9-HPT): je rychlý kvantitativní test. Měří se čas, za který vyšetřovaný umístí kuličky do otvorů a poté je vrátí zpět na původní místo. Pro svoji jednoduchost je využíván často u diagnóz jako roztroušená skleróza, Parkinsonova nemoc, mozková příhoda, také je využíván klinickými studiemi ke kvantifikaci poruchy funkce horní končetiny.<sup>25</sup>

### 4. Chůze

- Timed 25-Foot Walk, Timed up and go tests (TUGs), Six-Minute Walk Test (6MWT): základním principem těchto testů je měření rychlosti chůze.<sup>26</sup>

### 5. Komplexní pohybové škály, celkový stav

- Expanded Disability Status Scale (EDSS): hodnotí se 7 funkčních systémů - zrakový, kmenový, pyramidový, mozečkový, senzitivní, mentální a sfinkterové funkce. Dále je hodnocena vzdálenost chůze, kterou pacient ujde nebo úroveň mobility a základní sebeobsluhy, posuzována je též schopnost polykání. Škála je zlatým standardem hodnocení tíže onemocnění při roztroušené skleróze a jako endpoint prakticky všech klinických studií týkajících se této diagnózy.<sup>27</sup>
- Movement Disorder Society - Unified Parkinson's Disease Rating Scale (MDS-UPDRS): první, dotazníková část hodnotí pacientem udávané non-motorické příznaky (změny nálady, mentální aktivitu, autonomní funkce, spánek, chování a schopnosti vykonávat běžné činnosti denního života). Druhou část představuje klinické vyšetření zaměřené na motorické

symptomy a motorické komplikace léčby. Jedná se o nejčastěji používanou škálu pro potřeby monitorace a hodnocení klinických studií Parkinsonovy nemoci.<sup>28</sup>

- Hoehn and Yahr Scale (H-Y): jednoduchá běžně používaná škála hodnotící celkové pohybové postižení u pacientů s Parkinsonovou chorobou.<sup>29</sup>
- National Institute of Health Stroke Scale (NIHSS): je jednoduchou stupnicí vyjadřující tíži deficitu při cévních mozkových příhodách. Hodnotí stav vědomí, řečové funkce, okulomotoriku, zorné pole, mimické svalstvo, taktilní cití a hybnost jednotlivých končetin.<sup>20</sup>
- Fugl-Meyer Assessment (FMA): komplexní motorická škála určená k vyšetření pacientů po mozkových příhodách.<sup>30</sup>
- Motor Assessment Scale for Stroke: jednoduchá motorická škála testující 8 základních pohybových dovedností (přesuny mezi pozicí vleže na zádech, na boku, do sedu a stoje, chůze, funkce horní končetiny)
- Scale for the Assessment and Rating of Ataxia (SARA): jednoduchá škála ke kvantifikaci ataxie chůze, trupu, končetin a řeči. Představuje výběr klíčových úloh ze škály ICARS.<sup>31</sup>
- International Cooperative Ataxia Rating Scale (ICARS): komplexní škála určená ke kvantifikaci ataxie, zahrnuje vyšetření chůze, stoje, končetin, řeči a okulomotoriky.<sup>31</sup>
- Revised Hammersmith Scale (RHS): komplexní škála určená k vyšetření motorických funkcí zejména při sledování vývoje onemocnění spinální svalové atrofie ev. svalových dystrofií.<sup>32</sup>

## Zařízení k analýze lidského pohybu

Motion capture devices (mocap) jsou zařízení schopná zachytit pohyb objektů nebo lidí. Široké uplatnění mají komerční sféře v kinematografii, při vývoji videoher, sledování sportovních výkonů, ale i v armádním prostředí. Současný technologický pokrok přináší řadu možností jakým způsobem lidský pohyb zachytit. V následující části je přehled nejčastěji využívaných technologií pro medicínské účely.

### 1. Akcelerometry

Moderní tříosé akcelerometry snímají dynamické (pohyb akcelerometru) a statické (gravitační) zrychlení ve třech osách. Většina těchto senzorů spadá do kategorie mikro-elektrických mechanických systémů (MEMS). Podle principu fungování je nejčastěji můžeme rozdělit na kapacitní, piezoelektrické a piezorezistivní. Akcelerometry se také mohou lišit v řadě parametrů – v citlivosti, maximálním a dynamickém rozsahu, frekvenčním rozsahu, vzorkovací frekvenci, hmotnosti a digitálním či analogovém charakteru výstupního signálu. Fakt, že akcelerometry měří lineární zrychlení, je limituje v detekci rotačních pohybů, tento problém je však řešitelný kombinací 2 a více akcelerometrů eventuálně jejich sdružení s gyroskopickými čidly.<sup>33</sup>

Nespornou výhodou akcelerometrů jsou malé rozměry, nízké nároky na spotřebu energie, vysoká přesnost, cenová dostupnost a možnost provádět dlouhodobé měření v jakémkoliv prostředí.

Mezi hlavní problémy patří nutnost kalibrace systému před zahájením měření, posun neboli „drift“, který vzniká změnami vnitřních mechanických a elektrických vlastností zařízení zejména v závislosti na teplotě prostředí, šum vycházející z mikroskopických pohybů vlastních součástí senzoru a efekt gravitace. Pohybové artefakty pramenící z výše uvedených důvodů lze částečně eliminovat matematickými metodami.



## 2. Gyroskopická čidla

Gyroskopy jsou oproti akcelerometrům určené ke snímání úhlového zrychlení. Spolu s akcelerometry bývají zařazovány do skupiny inerciálních čidel. Všechny typy gyroskopů až na optické gyroskopy, obsahují neustále se pohybující část situovanou uvnitř zařízení, úhlové zrychlení je odvozeno z měření Coriolisovy síly. Neustálý pohyb čidla je spojen s vyššími energetickými nároky oproti akcelerometrům. Obdobně jako u jiných MEMS je měření gyroskopickými čidly zatíženo matematicky korigovatelnými artefakty vycházející ze šumu a posunu.<sup>33</sup>

## 3. Magnetometry

Magnetometry registrují velikost a podle jejich typu i směr a změnu magnetického pole. V kinematické analýze jsou využívány tříosé magnetometry registrující pohyb vůči magnetickému pólu Země. Využití mají v kombinaci s akcelerometry a gyroskopickými čidly jako součást pohybových senzorů.<sup>34</sup>

## 4. Inerciální měřící jednotky (IMU)

IMU (Inertial Measurement Unit) je zařízení kombinující akcelerometr, magnetometr a gyroskopické čidlo. Aktuálně se jedná o cenově snadno dostupná zařízení, která nachází široké možnosti uplatnění mimo jiné i v medicíně. Fúzí dat a jejich filtrací (často je využíván Kalmanův filtr) ze všech čidel je dosaženo přesnější rekonstrukce pohybu. Drift neboli posun jakožto společná slabina všech komponent IMU je někdy kompenzovaná kombinací s GPS lokátorem.

Malé rozměry a jednoduchá aplikace IMU zajišťují komfort pro vyšetřovanou osobu i při dlouhodobém sledování.<sup>12</sup>

Příklady zařízení obsahující IMU:

Medicínské uplatnění při monitoraci pohybu mají samotné senzory nebo zařízení, které tyto senzory obsahují. Může se jednat mobilní telefony, chytré hodinky či náramky nebo nositelná zařízení

obsahující více IMU ve formě obleků či postrojů. Příkladem zařízení obsahující vícero senzorů je Perception Neuron od výrobce Noitom, který byl využíván v našich měřeních.

## **5. Goniometry a torsiometry**

Elektrogoniometry a torsiometry jsou zařízením určeným k dynamickému měření úhlů a rotace. Využití mají zejména při měření rozsahu pohybů v kloubech. Kromě klasických mechanických goniometrů a torsiometrů existují i optické flexibilní varianty, které jsou založené na principu změny polarizace laserového paprsku při průchodu flexibilním optickým vláknem. Flexibilní zařízení kompenzují fakt, že lidské klouby mají variabilní centrum rotace a lze je využít i při měření rozsahu pohybu páteře.<sup>33,35</sup>

## **6. Nositelné (wearable) povrchové EMG**

Elektrody aplikované na kůži měří elektrickou aktivitu provázející svalovou kontrakci. Přináší informaci o aktivitě povrchově uložených svalů. Využívá se ke sledování a diagnostice extrapyramidových poruch nebo k hodnocení optimálního zapojení svalových skupin při komplexních pohybech jako je například chůze.<sup>33,36</sup>

## **7. Optoelektronická zařízení**

Jsou založeny na snímání objektů pomocí kamerových systémů. K detekci jednotlivých částí těla se používají značky, které mohou odrážet světelný signál emitovaný vlastním zařízením nebo které vyzařují elektromagnetické záření určité vlnové délky (často se jedná o světlo-emitující diody), které je zaznamenáno nahrávacím zařízením. Kombinací několika kamer umístěných po obvodu vyšetřované oblasti lze triangulací získat trojrozměrnou rekonstrukci pohybu. Výhodou těchto zařízení je přesnost určení polohy a nepřítomnost vodičů. Významným problémem je vysoká pořizovací cena, náročná kalibrace, omezení vyšetřovacího prostoru a obtížná přenositelnost zařízení.<sup>37</sup>

Cenově dostupnou variantou jsou zařízení s hloubkovými senzory obsahující infračervený projektor a infračervené kamery. Kombinací s RGB kamerou je možné rekonstruovat pohyb osoby. Tato

zařízení jsou snadno přenosná. Jejich hlavní nevýhodou je nižší přesnost, nedostatečné rozlišení pohybu prstů, limitace na krátkou vzdálenost a chyby v detekci částí těla, která se nachází v zákrytu vůči snímajícímu zařízení.<sup>38,39</sup>

## **8. Tlakové senzory**

### **a. Tlakové podložky**

Obsahují hustou síť tlakových senzorů snímající vertikální zatížení v čase. V závislosti na velikosti jsou obvykle využívány při analýze stoje či chůze, měření výchylek těžiště, rozložení tělesné hmotnosti a hodnocení funkce nohy. Obvykle jsou z dat k hodnocení extrahovány časové a prostorové parametry.

Nevýhodou je vysoká pořizovací cena, omezený vyšetřovací prostor, nemožnost měření horizontální složky síly. Při analýze chůze je nutno zohlednit fakt, že zařízení registruje pouze kontakt malé části těla s podložkou (obvykle chodidlo) a uniká tak informace o chování zbytku těla, zejména pak při švihové fázi chůze, kdy končetina není s podložkou v kontaktu. Ačkoliv se jedná o přesnou metodu měření, při komplexní analýze chůze se zdají přínosnější pohybové senzory typu IMU.<sup>40-42</sup>

### **b. Vložky do bot**

Podle typu tenzometru mohou být kapacitní, piezoelektrické či piezorezistivní nebo rezistivní. Oproti tlakovým podložkám mají nespornou výhodu v kontinuální monitoraci v jakémkoliv prostředí. Nevýhoda v podobě ztráty prostorové informace může být kompenzována kombinací s akcelerometrem.<sup>43,44</sup>

## **9. Aktigrafická čidla**

Aktigrafy slouží zejména k monitoraci denní a noční aktivity a hodnocení biorytmů v přirozených podmínkách vyšetřovaného. Nejčastěji mají podobu náramků či hodinek, mohou být upnuty ale i na dolní končetiny nebo hrudník. Akcelerometr jako základní součást zařízení může být doplněn o

GPS lokátor, oxymetr a elektrokardiogram, což umožňuje mimo jiné i rozlišení jednotlivých spánkových stádií. <sup>45</sup>

Často zmiňovaným nedostatkem je narůstající chyba v odhadu celkového výdeje energie při izometrické zátěži. <sup>46</sup>

## **10. Další možnosti sledování pohybové aktivity**

K lokalizaci polohy a monitoraci pohybu uvnitř budov jsou k dispozici komerční systémy často využívané v rozsáhlých halách a skladech. Využívají principu radiolokace s využitím wi-fi, radiových vln <sup>47,48</sup>, sonaru či infračerveného záření s přesností detekce v řádech desítek centimetrů až jednotek metrů. Ve venkovních prostorách jsou využívány satelitní navigační systémy (GPS, Galileo apod.) s cílem sledování pohybové aktivity v průběhu dne. <sup>49</sup>

Kombinací dat získaných z vícero odlišných zařízení lze dosahovat vyšší přesnosti. <sup>10,50</sup>

## **Předzpracování dat**

Syrová data získaná pomocí inerciálních senzorů, zvláště pokud jsou zaznamenána mimo laboratorní prostředí obsahují artefakty například v podobě posunu nebo šumu. Záznam také může obsahovat úseky, které nejsou předmětem hodnocení.

Běžnou strategií k odstranění šumu a vyhlazení dat je digitální filtrování. Výběr požadovaných úseků záznamu lze provést manuálním výřezem. Sofistikovanější možností je tvorba algoritmu rozpoznávajícího klíčové body signálu jako je například lokální minimum ve vertikální ose odpovídající kontaktu nohy s podložkou při detekci kroků nebo rotace podél vertikální osy při změně směru chůze. Při dostatečně velkém vzorku dat se k rozpoznání požadovaných úloh uplatní umělé neuronové sítě.

## Parametrizace dat

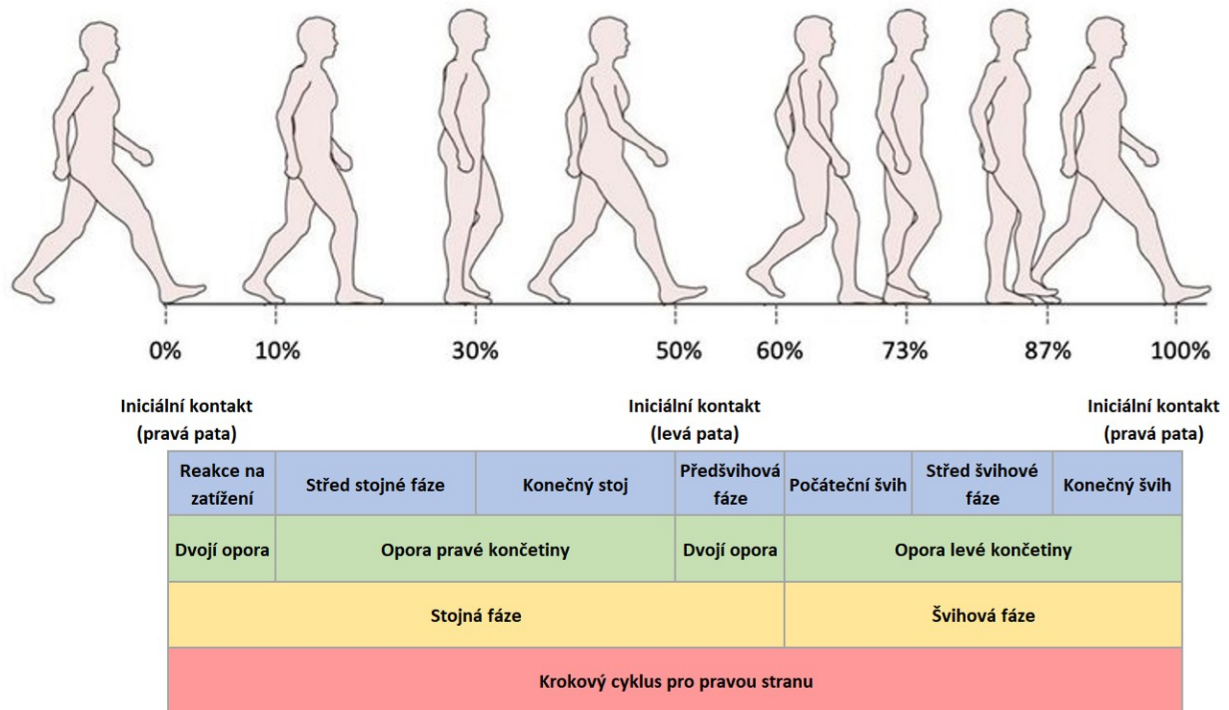
Parametr je měřitelná vlastnost pozorovaného děje. Za účelem efektivní klasifikace, regrese či detekce charakteristických vzorů je zásadní výběr nezávislých parametrů s vysokou informační či diskriminační hodnotou. Parametry mohou nabývat číselných hodnot, grafické podoby nebo mohou být kategorického charakteru.

V následujícím textu je přehled nejčastěji využívaných parametrů k analýze pohybu. Nejčastěji využívané jsou parametry založené na časové a prostorové doméně, frekvenční analýze, méně častěji na principu entropie eventuálně na jiných matematických metodách.

### 1. Analýza chůze

Chůzi lze je dopředný pohyb vzpřímeného těla, který je vykonávaný rytmickým střídáním dolních končetin. Při normální chůzi připomíná trajektorie těžiště v horizontální i vertikální rovině sinusovou křivku. Základní periodicky se opakující jednotka chůze je označována jako krokový či chůzový cyklus (gait cycle), jež je tvořen dvěma základními fázemi. Stojná fáze (stance phase) je ta část cyklu, kdy je noha v kontaktu se zemí, obvykle trvá přibližně 60 % doby celého cyklu. Při švihové fázi (swing phase) se končetina pohybuje vpřed a není v kontaktu s podložkou, tato fáze trvá obvykle přibližně 40 % cyklu.<sup>51</sup> Celý krokový cyklus je znázorněn na obr. 1.

Jako obvyklý začátek chůzového cyklu je uváděn prvotní kontakt paty s podložkou. Následuje reakce na zatížení, střed stojné fáze, konečný stoj a předšvihová fáze. Na začátku a konci stojné fáze jsou obě dolní končetiny v kontaktu se zemí, což je označováno jako fáze dvojí opory (double support). Švihovou fázi lze rozdělit na počáteční švih, střed švihové fáze a konečný švih. Krokový cyklus končí dalším počátečním kontaktem stejné končetiny.<sup>51</sup>



Obr. 1: Schéma krokového cyklu s relativním trváním jednotlivých fází

Nejčastěji sledované parametry odrážejí prostorové a časové vlastnosti měřené pohybové aktivity. Osa ve směru chůze je zpravidla označována jako  $x$  vertikální osa  $z$  a horizontální osa kolmá ke směru pohybu  $y$ .

- Variabilita amplitudy zrychlení: průměrná směrodatná odchylka (SD) velikosti zrychlení končetin nebo trupu ve směru jednotlivých prostorových os ( $x$ ,  $y$ ,  $z$ ).
- Kadence: počet kroků za časovou jednotku.
- Čas dvojitě opory (double support time): časový úsek, kdy jsou obě dolní končetiny v kontaktu s podložkou. Může být vyjádřen v časových jednotkách nebo jako podíl z celkového trvání krokového cyklu.
- Trvání krokového cyklu: délka trvání celého krokového cyklu neboli „dvojkroku“. Obvykle začíná kontaktem paty s podložkou a končí následujícím kontaktem stejné nohy s pod-

ložkou. K vyjádření míry variability lze využít směrodatné odchylky v trvání jednotlivých kroků či krokového cyklu.

- Laterální odchylka nohy: míra odchýlení došlapu v ose  $y$ .
- Šířka baze: vzdálenost mezi chodidly na ose  $y$  ve fázi dvojité opory. Lze využít i variabilitu šíře baze při chůzi jako směrodatnou odchylku získaných hodnot.
- Uražená vzdálenost: délka uražené vzdálenosti ( $m$ ).
- Rychlost chůze: vzdálenost v metrech uražená za sekundu.
- Trvání stojné fáze: trvání stojné fáze vyjádřené v sekundách nebo jako poměr z celkového trvání krokového cyklu.
- Trvání švihové fáze: trvání švihové fáze vyjádřené v sekundách nebo jako poměr z celkového trvání krokového cyklu.
- Trvání kroku: délka trvání jednoho kroku či dvojkroku, resp. celého krokového cyklu.
- Frekvence kroků: počet kroků nebo dvojkroků za sekundu.
- Délka kroku nebo dvojkroku: vypočtená jako poměr uražené vzdálenosti a počtu kroků, nebo jako průměrná naměřená délka jednotlivých kroků. Při znalosti akcelerace trupu lze délku kroku lze odvodit i z modelu převráceného kyvadla jako  $2\sqrt{(2lh - h^2)}$ , kde  $l$  je délka dolní končetiny v metrech ( $m$ ) a  $h$  je amplituda vertikální odchylky ( $m$ ) během krokového cyklu.<sup>33,52</sup>
- Harmonic ratio: vychází z diskrétní Fourierovy transformace, je poměrem součtu sudých a lichých harmonických amplitud. Tento parametr charakterizuje plynulost a rytmicitu a symetrii jednotlivých kroků.<sup>53</sup>
- Rezonanční frekvence: představuje frekvenční spektrum s nejvyšší energií získané Fourierovou transformací (FT).<sup>54</sup>
- Energie signálu: průměrná energie signálu ve zvoleném frekvenčním pásmu po provedení Fourierovy transformace.<sup>55</sup>
- Entropie: využívá se ke kvantifikaci pravidelnosti, respektive nepředvídatelnosti fluktuací dat, které mají charakter časových sérií. Na základním principu aproximační entropie jsou založeny i novější metody jako sample, fuzzy, multiscale nebo například permutační entropie. Entropie rychlosti nebo stranových úchylek těžiště během chůze koreluje s mírou nestability při chůzi.<sup>56-58</sup>
- Symetrie: Některé parametry mohou být vyjádřeny jako poměr mezi pravou a levou stranou.



Symetrie nabývá hodnoty 0 (žádná symetrie) až 1 (dokonalá symetrie). Příkladem může být symetrie délky nebo trvání kroku, ale i celková energie v jednotlivých frekvenčních pásmech.<sup>53,59</sup>

## 2. Analýza stoje

- Rozsah zrychlení: rozsah absolutních hodnot zrychlení trupu v horizontální rovině.
- Průměrné zrychlení, kvadratický průměr zrychlení: vypočtené ze zrychlení trupu v horizontální rovině.
- Průměrná vzdálenost: délka trajektorie senzoru či odhadovaného těžiště, ev. její kvadratický průměr.
- Délka trajektorie: vzdálenost ( $m$ ) uražená akcelerometrem, ev. vztažená k času.
- Sway Area: celková velikost plochy ohraničené dráhou akcelerometru ( $m^2$ ), ev. její hodnota vztažená k času.
- Jerk Index: derivace zrychlení podle času, vyjadřuje plynulost oscilací těžiště.
- Centrum spektra: průměrná frekvence celé frekvenční oblasti získaného signálu, vychází z Fourierovy transformace.
- Průměrná frekvence: průměrná frekvence výkonnostního spektra získaného analýzou zrychlení.
- Entropie: v různých modalitách, např. sample nebo fuzzy entropie
- Průměrná rychlost oscilací: vypočtená jako první integrál hodnot zrychlení v horizontální rovině.<sup>56,57,60</sup>
- Energie signálu: hodnota energie signálu ve vybraném intervalu, vypočtená z frekvenční analýzy hodnot zrychlení trupu.

## 3. Analýza pohybu končetin

Obdobně jako při analýze chůze a stoje jsou využívány parametry s časovou nebo prostorovou doménou. Popisují rychlost, rozsah pohybu, lze porovnávat aktivní čas jednotlivých končetin a podobně. Nelineární parametry vycházející z frekvenční analýzy (např. rezonanční frekvence, energie signálu) jsou vhodné k analýze tremoru a jeho klasifikaci. entropie (v různých modalitách) a fraktální analýza vyjadřují míru komplexity pohybu, jeho trajektorie nebo změn zrychlení. Využití

mají při kvantifikaci plynulosti pohybu (taxe) a schopnosti vykonávat rytmické pohyby (diadochokinéza, test pronace-supinace, finger- a foot-tapping).

Rozsah pohybu končetiny je vyjádřen změnou úhlu v krajních polohách kloubu. K výpočtu se využívá akcelerometrický nebo gyroskopický signál, jehož parametry slouží jako vstupní informace pro výpočet pomocí goniometrických funkcí. <sup>61-63,63</sup>

## Balancování parametrů a normalizace dat

Parametry získané ze syrových dat se mohou lišit jednotkami, hodnotou a jejím rozptylem, což může vést u velké části klasifikačních algoritmů ke zkreslení výsledku. K transformaci dat jsou využívány metody normalizace podle průměru nebo rozptylu s výstupními hodnotami  $x' \in \langle 0;1 \rangle$  nebo standardizace podle z- a t-skóre, kdy  $x' = 0$  a směrodatná odchylka  $\sigma = 1$ .<sup>64</sup>

Při rozdílném počtu vzorků v jednotlivých třídách (např. rozdílný počet zdravých kontrol a nemocných subjektů) je prováděno jejich balancování za účelem zachování robustnosti a předcházení over-fitting efektu. Využívány jsou například metody podvzorkování, převzorkování, přidání šumu nebo metoda SMOTE (Synthetic Minority Oversampling TEchnique).<sup>65</sup>

## Redukce dimenzionality

Biosignály reprezentované velkým počtem proměnných nebo velkým počtem jednotlivých pozorování jsou obtížně zpracovatelné a jejich prezentace může být komplikovaná. Metodami redukce dat jsou vícerozměrná data redukována do méněrozměrného prostoru tak, že jsou zachovány některé vlastnosti dat původních. Výhodou je datový soubor o menších rozměrech s nižšími nároky na výpočetní výkon. Využití má při redukci šumu, pro přehlednější grafickou interpretaci dat, klastrovou analýzu a nebo jako mezikrok ke zvýšení účinnosti následného strojového učení. Jednodušší redukční techniky jsou založené na ovlivnění výběru parametru. Komplexnější techniky využívají transformaci dat do komponent nebo projekci vícerozměrných dat do prostoru o nižším počtu dimenzí. <sup>66</sup>

**Missing Value Ratio** – metoda vynechávající proměnné s vysokým počtem chybějících hodnot.

**Low Variance filter** – technika vynechávající proměnné obsahující konstantní hodnoty.

**High Correlation filter** – vzájemně korelované proměnné (vycházející z Pearsonova korelačního koeficientu) nemají přidanou informační hodnotu a mohou zkreslit výsledek analýzy. Touto metodou jsou významně korelované prvky vynechány.

**Random Forest** (náhodný les) – technika strojového učení se schopností vyhodnotit významnost vstupních proměnných pro následnou klasifikaci. Ke klasifikaci lze využít libovolný počet nejvýznamnějších faktorů.

**Backward Feature Elimination** and **Forward Feature Selection** – algoritmus opakovaně hodnotí úspěšnost klasifikace po postupné eliminaci nebo přidání jedné proměnné a hledá tak ty proměnné, které mají na úspěšnost největší vliv. Pro vysoké výpočetní nároky je tato metoda využívána u méně objemných dat.

**Factor Analysis** – technika vhodná pro situace s vysoce korelovanými proměnnými, které jsou rozdělené do odlišných skupin reprezentovaných faktorem.

**Principal Component Analysis (PCA)** - je jednou z nejčastěji využívaných metod ke zpracování lineárních dat. Lineární kombinací vstupních hodnot vznikají hlavní komponenty, které jsou

extrahovány tak, že první hlavní komponenta popisuje největší část variance dat, každá následující hlavní komponenta není korelována s komponentou předchozí a popisuje zbývající varianci.

**Independent Component Analysis (ICA)** - transformuje a popisuje data pomocí nižšího počtu nezávislých komponent.

**t-distributed stochastic neighbor embedding (TSNE)**: metoda vhodná k analýze vysoce nelineárních dat a pro jejich vizualizaci. Využívá projekci dat na varietu (n-rozměrný topologický prostor).

**Uniform Manifold Approximation and Projection UMAP**: podobně jako TSNE má využití u vysoce rozměrných nelineárních dat. Výhodou oproti TSNE je lepší schopnost reprezentovat velké soubory dat a kratší výpočetní čas.<sup>67</sup>

## Metody strojového učení (machine learning)

Za účelem automatického zpracování a třídění dat lze využít metody strojového učení. Jedná se o algoritmy schopné se učit a následně klasifikovat objekty do jednotlivých tříd eventuelně objekty shlukovat do skupin či provádět regresi s cílem odhadu výstupních hodnot.

Podle způsobu učení rozdělujeme strojové metody na “supervised” neboli s učitelem nebo “unsupervised” neboli bez učitele a “reinforcement learning” neboli zpětnovazebné učení.

Strojové metody s učitelem využívají jako vstupní informaci parametry popisující vlastnosti získaných dat. Algoritmus se učí na trénovacích datech s předem určenými výstupními hodnotami. Poté je schopen rozhodovat o výstupních parametrech.

Strojové metody bez učitele využívají jako vstupní informaci pouze získané parametry, následně hledají vhodné nastavení pro třídění analyzovaných dat, například tvořením shluků objektů s podobnými vzory.

Obvykle se vstupní data dělí na trénovací sadu, na které se model učí rozpoznávat vzory a na sadu testovací, která slouží k validaci.

### 1. Logistická regrese

vychází z logistické funkce. Narozdíl od lineární regrese ji lze aplikovat i na data, která nejsou lineárně separovatelná. Rozhodovací hranice má tvar sigmoidy.<sup>68</sup>

### 2. Support Vector Machine (SVM)

je binární klasifikátor separující data pomocí nadroviny, která tvoří maximálně široké hraniční pásmo (margin) mezi nejbližšími body (support vectors) obou tříd. V případě, že takovou rovinu nelze sestrojít, zavádíme proměnnou nastavující kompromis (trade-off) mezi šířkou hraničního pásma a počtem chybně klasifikovaných bodů. Aplikací jádrového triku (kernel trick) lze data transformovat do vyšší dimenze, kde mohou být již lineárně separována. Zpětnou projekcí do dvojrozměrného grafu se zobrazí nelineární křivka rozdělující obě skupiny. Běžně používané jádrové triky jsou Gaussovské radiální bázové funkce a hyperbolické funkce. Metodu lze využít i k regresi.<sup>69</sup>

### 3. Naive Bayes

je založená na pravděpodobnostním modelu strojového učení, předpokládá že vstupní parametry jsou náhodné navzájem nezávislé proměnné. Rozhodnutí, ke které třídě daný vzorek náleží je dán výpočtem hustoty pravděpodobnosti. Kombinací s metodami odhadu jádrové hustoty (Kernel Density Estimation) lze dosáhnout vyšší účinnosti. <sup>68</sup>

### 4. K-Nearest Neighbor (k-NN)

Algoritmus postavený na jednoduchém principu určený jak ke klasifikaci, tak k regresi. Základní myšlenkou je výběr nejbližších objektů umístěných v ploše grafu vůči hodnocenému vzorku. Testovanému vzorku je přiřazena taková třída, kterou je označena většina sousedních vzorků. Počet sousedních vzorků  $k$  je libovolné liché číslo. Nevýhodou této metody je vyšší náročnost na výpočetní čas pro objemnější soubory. <sup>68</sup>

### 5. Decision Tree

Rozhodovací strom je jednoduchým neparametrickým algoritmem schopným klasifikace i regrese. Cílem rozhodovacího stromu je nalézt nejefektivnější způsob, který na základě vstupních parametrů a jednoduchých rozhodovacích pravidel odhadne cílovou hodnotu. Rozhodování probíhá v uzlových bodech, ze kterých vede konečný počet větví. Nastavení rozhodovacích podmínek je optimalizováno pomocí entropie, která nepřímou udává informační hodnotu rozhodnutí. Výhodou rozhodovacího stromu je jeho jednoduchá interpretovatelnost, robustnost, vhodnost k analýze velkých souborů. Metoda nevyžaduje normalizaci vstupních parametrů a je sama schopna vyhodnotit, které parametry jsou rozhodující pro účinnou klasifikaci. Nevýhodou je například riziko přeučení tzv. overfitting.

### 6. Random Forest

Náhodný les vzniká kombinací několika rozhodovacích stromů, jejichž predikce mají váženou hodnotu. Predikovaná hodnota je modem (nejčastější hodnotou) vrácených hodnot jednotlivými stromy. Modifikací tohoto algoritmu je tzv. bootstrap metoda. Metodu lze použít ke klasifikaci i regresi. Náhodný les kompenzuje nedostatek samotných rozhodovacích stromů v podobě overfittingu. <sup>68</sup>

## 7. Neuronová síť (Neural network, NN)

Algoritmus inspirovaný uspořádáním neuronů mozku u živočichů. Kromě klasifikace ji lze využít i k rozpoznávání struktur, kompresi obrazů nebo zvuků a k předvídání vývoje časových řad.

Problematika umělých neuronových sítí je širokým tématem daleko přesahující rozsah této práce, pro účely stručného přehledu jsou zmíněny základní informace.

Umělé neuronové sítě jsou složeny z navzájem propojených neuronů pomocí hran (edges). Každý neuron může mít neomezený počet vstupů, ale pouze jediný výstup. V průběhu učení získávají jednotlivé hrany přenášející vstupní vzorek k neuronu relativní váhu. Neuron na základě vnitřní funkce zpracuje přijaté vzorky vážené podle jejich významu a odesílá signál dalším neuronům. Obvykle se neurony seskupují do hustě propojených vrstev s různými vlastnostmi. Mohou tak vznikat jednoduché sítě o malém počtu neuronů v jedné nebo dvou vrstvách nebo komplikované vícevrstvé sítě o velkém počtu neuronů s variabilními funkcemi a propojením.

Podle typu učení lze umělé neuronové sítě rozdělit na „supervised“ nebo „unsupervised“ neboli s a nebo bez učitele. Existuje řada metod, jak trénovat neuronovou síť, jak určit hodnoty vah a jak balancovat odchylky. Zjednodušeně lze říct, že komplexní neuronové sítě dosahují vyšší přesnosti za cenu vyšších nároků na výpočetní čas. Výhodou komplexních (hlubokých) neuronových sítí je možnost přímé analýzy dat bez nutnosti parametrizace signálu.<sup>55,70</sup>

## 8. Adaptive Boosting (AdaBoost)

AdaBoost při klasifikaci lineárně kombinuje rozhodnutí několika „slabých“ klasifikátorů a potenciálně tak dosahuje lepších výsledků, než by bylo možno dosáhnout použitím klasifikátorů samotných. Tento algoritmus lze využít ke klasifikaci i regresi.

## 9. Majority Voting

Představuje jednoduchou metodou kombinující různé klasifikátory. Přijata je ta výstupní hodnota, která má největší zastoupení. Lze tak za cenu komplikovanějšího výpočtu dosáhnout vyšší přesnosti.<sup>71</sup>



## Evaluace účinnosti metod strojového učení

Spolehlivost a případný overfitting klasifikačního algoritmu se hodnotí křížovou validací (cross validation). Principem je rozdělení vzorku na testovací skupinu a několik skupin trénovacích.

Opakovaným učením na jednotlivých trénovacích skupinách a následným testováním je porovnávána přesnost modelu, výstupem je cross-validační chyba modelu. Běžně využívané cross-validační metody jsou např. *k-fold*, *leave-one-out*, *stratified cross validation*.

Úspěšnost klasifikace nelze paušálně vyjádřit jediným parametrem. Matice záměn (tabulka 1) popisuje vztahy mezi správnou a chybnou klasifikací.

Nejčastějšími parametry k porovnání klasifikačních modelů jsou: specificita, senzitivita, přesnost (accuracy), dále pak F1 skóre a Matthewsův korelační koeficient (MCC).

Příčemž:

$$F1 = \frac{2 \times \text{Pozitivní prediktivní hodnota} \times \text{Senzitivita}}{\text{Pozitivní prediktivní hodnota} + \text{Senzitivita}}$$

$$MCC = \frac{(\text{Správně pozitivní} \times \text{Správně negativní} - \text{Falešně pozitivní} \times \text{Falešně negativní})}{\sqrt{(\text{Správně pozitivní} + \text{Falešně pozitivní})(\text{Správně pozitivní} + \text{Falešně negativní})(\text{Správně negativní} + \text{Falešně pozitivní})(\text{Správně negativní} + \text{Falešně negativní})}}$$

Další možností je využití ROC křivky (Receiver Operating Characteristic curve), která slouží k porovnání a optimalizaci binárního klasifikačního systému (testu). Vyjadřuje vztah mezi specificitou a senzitivitou daného testu nebo detektoru pro všechny přípustné hodnoty prahu.<sup>72</sup>

Pro hodnocení úspěšnosti regresní analýzy jsou určeny metody vyjadřující, do jaké míry regresní křivka odpovídá získaným hodnotám. Základními parametry efektivity jsou střední kvadratická chyba, koeficient determinace ( $R^2$ ), střední polohová a střední absolutní chyba (RMSE, MAE).

Odhodvaný stav	Skutečný stav		Přesnost (Accuracy) = $(\Sigma \text{ Správně pozitivní} + \Sigma \text{ Správně negativní}) / \Sigma \text{ Celková populace}$
	Pozitivní stav	Negativní stav	
Celková populace			
Předpovězený stav pozitivní	Správně pozitivní	Falešně pozitivní, chyba I. typu	Prevalence = $\Sigma \text{ Pozitivní stav} / \Sigma \text{ Celková populace}$
Předpovězený stav negativní	Falešně negativní, chyba II. Typu	Správně negativní	False discovery rate = $\Sigma \text{ Falešně pozitivní} / \Sigma \text{ Předpovězený stav pozitivní}$
	Sensitivita = $\Sigma \text{ Skutečně pozitivní} / \Sigma \text{ Pozitivní stav}$	False positive rate = $\Sigma \text{ Falešně pozitivních} / \Sigma \text{ Negativní stav}$	False omission rate = $\Sigma \text{ Falešně negativní} / \Sigma \text{ Předpovězený stav negativní}$
	False negative rate = $\Sigma \text{ Falešně negativní} / \Sigma \text{ Pozitivní stav}$	Specificita = $\Sigma \text{ Správně negativní} / \Sigma \text{ Negativní stav}$	Negativní prediktivní hodnota = $\Sigma \text{ Správně negativní} / \Sigma \text{ Předpokládaný stav negativní}$
		Positive likelihood rate (LR+) = $\text{Senzitivita} / \text{False positive rate}$	Diagnostic odds ratio = $\text{LR+} / \text{LR-}$
		Negative likelihood rate (LR-) = $\text{False negative rate} / \text{Specificita}$	

Tabulka č.1: Rozšířená matice záměn (confusion matrix)

## **Aplikace v klinické praxi**

### **1. Parkinsonova choroba (PD)**

Tíže pohybového postižení při Parkinsonově nemoci, ke které patří rigidita, třes, poruchy chůze a rovnováhy a zarázy v chůzi (freezing), kolísá v průběhu dne. Kompenzovaný stav je označován jako „ON“, v pozdních stádiích onemocnění narůstá frekvence „OFF“ stavů s dekompenzovanou hypokinézou a častými pády. K objektivnímu vyšetření lze využít IMU (akcelerometry, magnetometry, gyroskopická čidla), optoelektrické systémy, tlakové podometry či povrchovou elektromyografii. Jako nejvhodnější se jeví nositelné inerciální senzory, jejichž výsledky dobře korelují se standardními klinickými škálami (H-Y, MDS-UPDRS), jsou dobře tolerovány a lze je využít k dlouhodobé monitoraci v domácím prostředí.<sup>12</sup>

Stanovení správné diagnózy má zásadní význam pro hodnocení prognózy a nastavení léčby, přesto je až 25% diagnóz Parkinsonovy nemoci nesprávných. Pohybová analýza pomocí senzorů diagnostický proces urychluje i zpřesňuje.<sup>10,19</sup>

Základní charakteristiky třesu jsou jeho intenzita, frekvence a situace kdy se třes vyskytuje (klidový, posturální, kinetický). Optimální parametry pro detekci a klasifikaci třesu vycházejí z frekvenční analýzy (energie signálu, rezonanční frekvence apod.)<sup>10</sup>

Pohyb končetin a chůze dobře charakterizují prostorově-časové parametry (např. průměrné zrychlení, délka trajektorie, délka kroku, frekvence kroků, rychlost chůze, entropie), parametry vycházející z frekvenční analýzy a hodnocení symetrie pohybu. Posturální stabilita vyšetřena akcelerometry umístěnými na pánvi a hlavě koreluje s tíží nemoci a se stavy ON a OFF, lze ji využít k predikci a následné prevenci pádů.<sup>10,12</sup>

### **2. Cévní mozkové příhody (CMP)**

Počet prací zabývajících se využitím senzorů v přednemocniční péči a diagnostice CMP v čase narůstá, přesto je převod do klinické praxe v tomto odvětví velmi vzdálený a jeho přínos je vzhledem k akutnosti onemocnění a nutnosti rychlého managementu sporný.

Pohybové senzory nacházejí využití zejména při sledování rekonvalescence, průběhu a efektu rehabilitace. <sup>13</sup>

K objektivizaci pohybu končetin jsou běžně využívány parametry odvozené z Fourierovy transformace, amplituda pohybu, počet pohybových epizod. Vzhledem k častému klinickému obrazu ve formě hemiparézy je výhodné sledování symetrie <sup>73</sup>

### **3. Alzheimerova nemoc (AD)**

Pohybové příznaky doprovázejí i onemocnění u kterých dominuje kognitivní postižení. S využitím IMU nebo tlakových senzorů u Alzheimerovy choroby lze pozorovat změny rychlosti chůze spolu s variabilní délkou kroků již několik let před rozvojem MCI (mírného kognitivního postižení).

Mobilní aplikace sledující frekvenci ťukání (analog finger-tapping testu) nebo počet úhozů na klávesnici za minutu koreluje s tíží kognitivního postižení. Stejně jako u chůze, odchylky od normy lze pozorovat několik let před projevy MCI.

Apatie, deprese jsou častými doprovodnými příznaky AD související s poklesem pohybové aktivity, tento jev lze monitorovat i pomocí GPS a aktigrafu. <sup>74</sup>

### **4. Roztroušená skleróza (RS)**

Mezi standardy testování funkce horní končetiny v menších experimentálních ale i velkých farmaceutických studiích patří Nine-Hole Peg Test (9-HPT). IMU vykazuje vysokou spolehlivost v rozlišení mezi skupinou pacientů a kontrol při sledování funkce horní končetiny v průběhu provádění klinických testů. Oproti běžným screeningovým škálám lze pomocí jediného senzoru na zápěstí spolehlivěji detekovat i nepatrné změny v obratnosti horní končetiny. <sup>18</sup>

Pro účely vyšetření chůze a stoje jsou nejčastěji pohybové senzory umístovány na dolní končetiny a do oblasti bederní páteře. Pozice na horní polovině trupu však přináší v některých případech spolehlivější výsledky. <sup>56</sup>

Hodnocení chůze a rovnováhy pomocí jediného senzoru v oblasti hrudníku či hrudní páteře významně koreluje se skóry klinických škál (EDSS, MSFC-4). Obdobně efektivní bylo několikátýdenní monitorování v domácím prostředí pomocí 3 IMU (hrudník, zápěstí, kotník), kde byly využity hluboké neuronové sítě k detekci chůze. <sup>46</sup>

K detekci ataxie chůze a dolních končetin jsou běžně využívány časové a prostorové parametry chůze (délka kroku a její variabilita, rychlost chůze, rozsahy pohybů, šíře baze).

<sup>75,76</sup>. Velkým přínosem jsou komplexní parametry, odvozené z frekvenční analýzy <sup>77-79</sup> nebo entropie. <sup>57,80</sup>

## 5. Poruchy spánku

Klasickou metodou vyšetření spánku je polysomnografie založená na kombinaci různých biosenzorů - elektroencefalogramu, elektrokardiogramu, povrchové elektromyografie, oxymetrie, sledování pohybů hrudníku a břicha při dechové aktivitě a sledování dynamiky a složení vydechaného vzduchu. Nevýhodou vyšetření je délka přípravy před samotným měřením a nutnost jeho provedení ve spánkové laboratoři specializovaného pracoviště.

Přínosem v diagnostice a rozlišení jednotlivých spánkových stádií jsou i pohybové senzory pro sledování pohybů končetin, 3D kamery pro rekonstrukci pohybů celého těla a sledování dechové aktivity. <sup>81-83</sup>

Sledování latence usnutí, délky spánku a nebo pohybů vázaných na spánek lze pomocí aktigrafie. Typické využití je spojené s monitorací nadměrné spavosti u narkolepsie, Parkinsonovy nemoci, syndromu obstrukční spánkové apnoe, poruch iniciace spánku nebo syndromu neklidných nohou. Poruchy spánku mohou i řadu let předcházet prvním motorickým či kognitivním poruchám spojeným s neurodegenerativními onemocněními. Včasná detekce poruch REM spánku může přispět ke včasné diagnóze a případnému brzkému zahájení léčby Parkinsonovy choroby, onemocnění s Lewyho tělísky nebo multisystémové atrofie.

Dostupnou možností a již komerčně rozšířenou jsou nositelné senzory obvykle umístěvané na zápěstí. Jednoduchý systém založený na sledování tělesné teploty, pohybu končetiny a EKG má 90% přesnost při identifikaci spánku a více než 50% přesnost při identifikaci bdělosti, REM a NON-REM stádií. <sup>84,85</sup>

## 6. Další uplatnění

Parametry chůze získané pomocí IMU mají klinické uplatnění i vyšetření abnormálních chůzových stereotypů, motorické dyspraxie a svalových dystrofií u dětí, poruchy chůze u dětské mozkové obrny, při klasifikaci a kvantifikaci míry ataxie u dědičných cerebelárních ataxií, sensorické ataxie u polyneuropatie, chorey při Huntingtonově nemoci nebo hodnocení průběhu rekonvalescence u poranění míchy či periferních nervů. Mimo neurologii je vyšetření pomocí senzorů aplikováno na revmatologická onemocnění kloubů anebo k hodnocení rehabilitace po traumatech muskuloskeletálního aparátu.<sup>33,56,86</sup>

## Současné problémy v analýze pomocí senzorů

Analýza pohybu pomocí nositelných senzorů dosahuje v řadě studií vysoké účinnosti. V současné době však není nastavená jednotná metodika sběru a analýzy dat. Pro úspěšné zavedení pohybových senzorů do běžné klinické praxe je nutno vyřešit několik základních otázek.

### 1. Optimální poloha a počet senzorů

Poloha senzoru ovlivňuje úspěšnost následné analýzy. Optimální poloha senzoru se liší podle sledovaného cíle. Počet senzorů by měl být omezen na nejnižší možný počet tak, aby byla zachována vysoká přesnost a zároveň zajištěn komfort vyšetření.

### 2. Volba parametrů

Výběr vhodného parametru nebo jejich kombinace je zásadní pro popis sledované činnosti a kvantifikaci nedostatků při jejím vykonávání. Alternativou jsou hluboké neuronové sítě (DNN), které tento krok obcházejí.

### 3. Klasifikační metoda

Volba nejefektivnějšího algoritmu nebo jejich kombinace musí brát ohled nejen na přesnost výsledků, ale i na výpočetní nároky. Mělké klasifikátory představují efektivní a rychlý způsob analýzy dat. Komplexní neuronové sítě vyžadují velké soubory vstupních dat a mají vysoké nároky na výpočetní čas během učení.

### 4. Detekce změn specifických pro sledované onemocnění

Již zavedenou aplikací je sledování vývoje klinického stavu v čase u onemocnění, jehož diagnóza je známá. Nejvyšší metou je rozlišení mezi jednotlivými symptomy a případně plně automatická diagnostika onemocnění. Řada postupů sleduje nespecifické změny, které se mohou vázat ke zcela odlišným nemocem. Příkladem je precizní analýza ataxie, jejíž vývoj lze kvalitně sledovat v čase. Zda se jedná o ataxii při postižení mozečku, polyneuropatii či poruchu rovnováhy při Parkinsonově nemoci je v současné době obtížně stanovitelné. S narůstajícím počtem studií a zpřesňováním metodiky je velmi pravděpodobné, že i tento problém bude překonán.<sup>12,60,87</sup>

### 5. Zpracování a ukládání velkých objemů dat

S narůstajícím objemem dat rostou výpočetní nároky na jejich zpracování. Data je možné zpracovat v reálném čase již samotným zařízením nebo je odesílat na centrální server. Otázkou je, která data ukládat, v jaké podobě a kam. Kromě paměťové kapacity samotného zařízení se nabízejí cloudová uložiska.

#### 6. Právní problematika v oblasti ochrany osobních údajů

Uchovávání dat a nakládání s daty obsahující osobní údaje, informace o pohybu osob, léčbě, zdravotním stavu a jejich zabezpečení jsou citlivým problémem současné doby, na který musí reagovat i současná legislativa.



## **Cíl disertační práce**

Snahou je přinést odpovědi na základní otázky na téma objektivizace pohybových poruch pomocí pohybových senzorů. Naše úsilí je zaměřeno na analýzu chůze, která je základním předpokladem soběstačnosti a základním pilířem kvality života. Její porucha ve formě ataxie je častým jevem doprovázející řadu získaných i dědičných neurologických nemocí.

Cílem práce je doložit efektivitu parametrů založených na frekvenční analýze akcelerometrického signálu, konkrétně energie signálu, za účelem detekce ataxie chůze. Dále porovnat úspěšnost běžných klasifikačních metod a metod hlubokého učení při detekci ataxie chůze s využitím energie signálu jako vstupního parametru pro učení. Najít optimální polohu senzoru pro detekci ataxie a popsat vliv jednotlivých metod redukce dat na výsledek klasifikace.

## Metody

Práce je rozdělá do třech částí. Nábor jedinců probíhal po celou dobu studie. V první části je na menším souboru jedinců ověřena informační hodnota energie signálu, co by parametru k detekci ataxie chůze a optimální poloha senzoru pro extrakci tohoto parametru.

V druhé části byly na rozšířeném souboru porovnávány algoritmy strojového učení včetně hlubokých neuronových sítí.

Na konečném souboru jedinců ve třetí části porovnáváme běžně používané mělké klasifikátory a metody redukce dimenzionality.

Projekt byl schválen lokální etickou komisí v souladu s Helsinskou deklarací z roku 1964.

## Část první

Tato práce je věnována detekci vzorů odvozených z akcelerometrických dat pomocí senzorů umístěných na různých částech těla. Sady experimentálních dat byly získány záznamem prvních 25 subjektů (13 zdravých kontrol a 12 pacientů s ataxií) s celkem 201 segmenty chůze o délce 20 s. Navrhovaná metoda zahrnuje použití diskretní Fourierovy transformace pro odhad středního výkonu ve vybraných frekvenčních pásmech  $<3, 15$ ) a  $<15, 30$ ) Hz a využití těchto parametrů pro klasifikaci segmentů dat. Hodnocení jsou založena na přesnosti klasifikace a chybě při cross-validaci při využití algoritmů support vector machine (SVM), Bayesovské metody, metody nejbližších sousedů (k-NN) a dvouvrstvé neuronové sítě (NN). Porovnány jsou výsledky získané ze signálů zaznamenaných na různých pozicích.

## Část druhá

Tato analýza se zabývá možností využití akcelerometrických dat k optimalizaci hlubokých neuronových konvolučních sítí k rozlišení ataxické a normální chůze. Rozšířený soubor obsahoval 19 zdravých kontrol a 16 pacientů s ataxií (celkem 840 segmentů v trvání 5 s). Hluboké neuronové sítě využívají celé frekvenční spektrum v rozsahu  $<0; 30$ ) Hz. Klasifikační výsledky jsou porovnány


s výsledky získaných standardními metodami, které zahrnují support vector machine, Bayesovské metody a dvouvrstvou neuronovou síť s parametry vyjádřenými jako relativní energie signálu v pás-  
mu  $<3, 15$ ) a  $<15, 30$ ) Hz.

### **Část třetí**

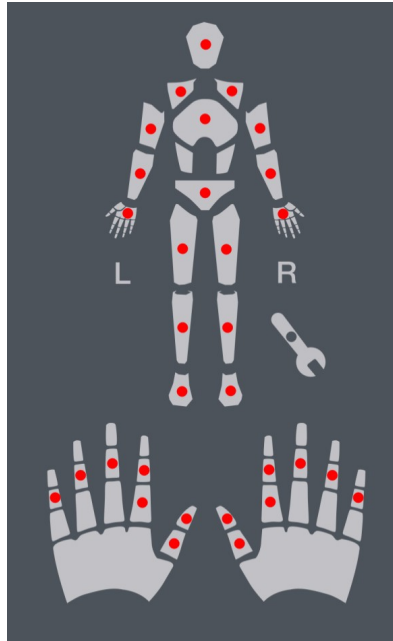
V této analýze srovnáváme metody redukce dimensionalit (PCA, TSNE, UMAP) a běžně používané klasifikační metody (SVM, k-NN, Bayesovskou klasifikaci, logistická regrese, decision trees, random forest, adaboost a dvouvrstvá neuronová síť). Testovaným souborem je celkem 33 subjektů (14 pacientů s ataxií a 19 zdravých kontrol) s celkem 316 segmenty rovné chůze. Zpracování dat a jejich vyhodnocení bylo provedeno v programovacím jazyku Python v prostředí platformy GitHub.

## Sběr dat

Pohybová data byla zaznamenána pomocí zařízení Perception Neuron (Noitom), které obsahuje až 31 inerciálních jednotek umístěných na končetinách, hlavě a trupu pomocí elastických popruhů. Jednotlivé senzory jsou tvořené 3-osým akcelerometrem 3-osým gyroskopem a 3-osým magnetometrem se vzorkovací frekvencí 60 nebo 120 Hz v závislosti na počtu připojených senzorů. Pro naše měření jsme využili zapojení minimálně 16 senzorů se vzorkovací frekvencí 60 Hz. Možnosti umístění senzorů na těle je znázorněno na obr. 3. Před každým vyšetřením proběhla kalibrace zařízení dle pokynů výrobce.



Obr. 2: a) Zařízení Perception Neuron při využití pohybových senzorů ve všech možných pozicích, b) „neuron“ inerciální měřící jednotka, c) rekonstrukce pohybu v programu Axis Neuron

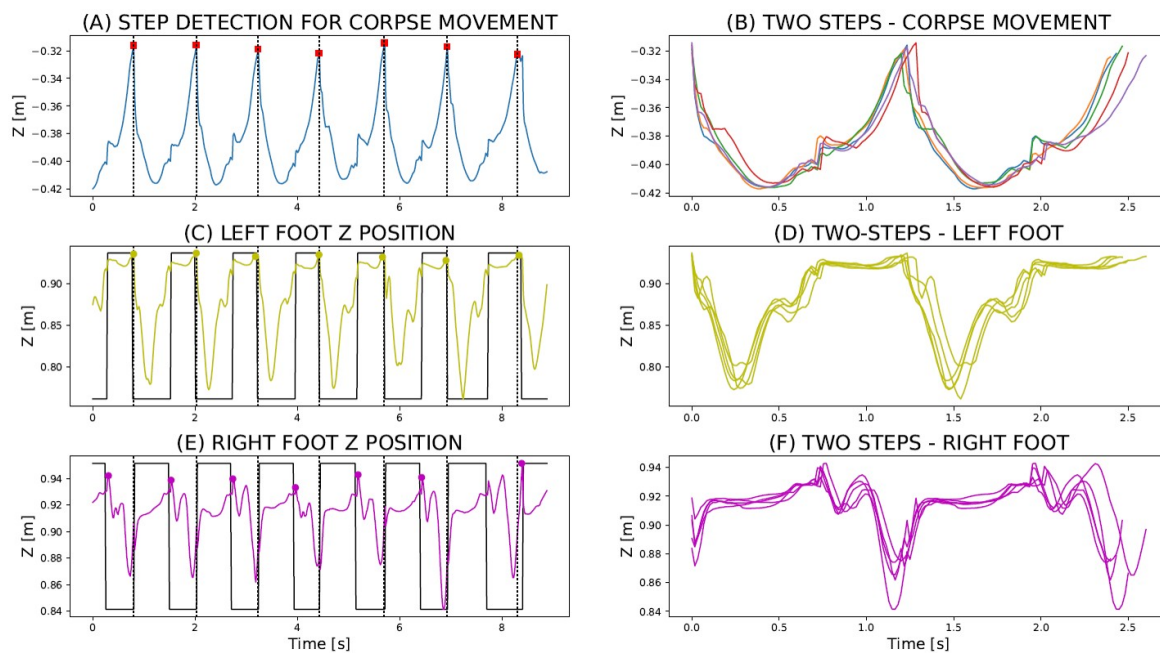


Obr. 3.: Možnosti umístění senzorů zařízení Perception Neuron.

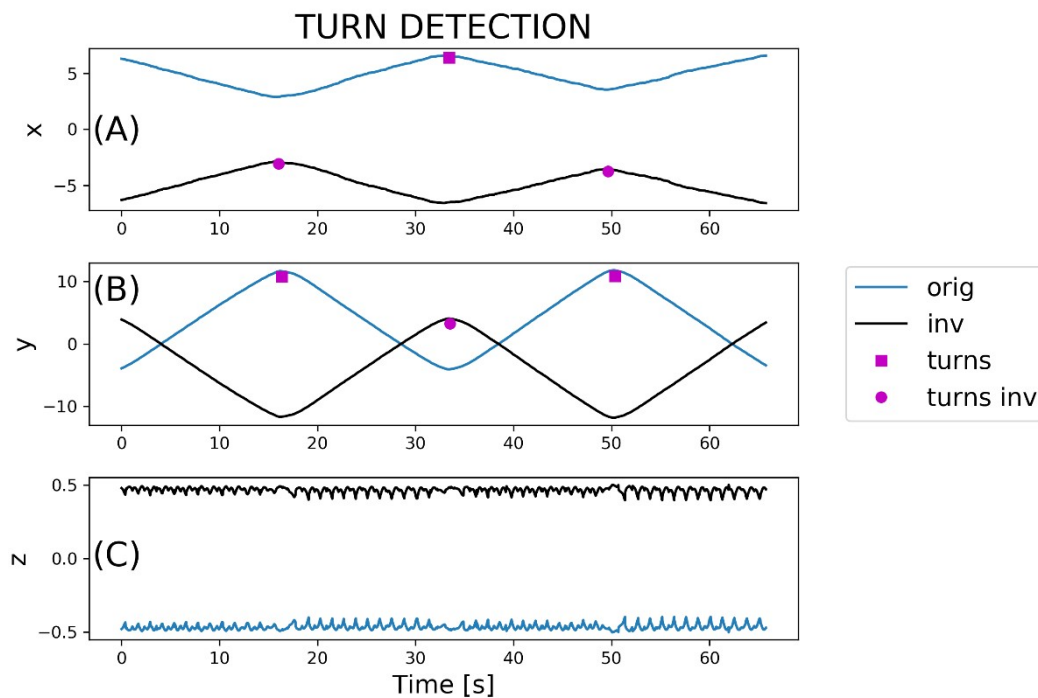
Sledované osoby chodili po nemocniční chodbě s hladkým povrchem o délce 20 metrů tam a zpět. Limitem byl časový úsek 5 minut nebo vyčerpání samotného jedince. Míra ataxie chůze byla stanovena neurologem podle klinické škály SARA (Scale for the Assessment and Rating of Ataxia). Vyšetřované osoby byly škálovány od 0 (normální chůze) do 3 (těžká ataxie, ještě se zachovanou schopností chůze bez kompenzační pomůcky).

Dále vyšetřované osoby prováděly pohybové úkony odpovídající běžnému neurologickému vyšetření a test jemné motoriky s využitím pomůcky „Purdue Pegboard“. Analýza pohybu těchto dalších vyšetření je předmětem jiných prací.

Získané záznamy byly ořezány o nežádoucí úseky (odpojení senzoru, přerušení úkolu, čas před a po provedení samotné chůze). Automatický algoritmus využívající detekci kroků a otoček byl aplikován k výběru rovných úseků chůze (obr. 4 a 5). Získané úseky rovné chůze byly dále rozděleny na kratší části o délce 20 s a nebo 5 s.




Obr. 4.: Metodika detekce kroků pro pohyb a) trupu, c) levé nohy a e) pravé nohy. Korespondující krokový cyklus b), d) a f) vycházející z detekce kroků.



Obr. 5.: Metodika detekce otoček při chůzi, a) extrémy v rovině x, b) extrémy v rovině y, c) extrémy v rovině z. Obrat při chůzi je označen fialovým bodem.


## Soubor jedinců

Měření se účastnilo celkem 33 subjektů; 14 pacientů s ataxií chůze a 19 zdravých kontrol. Věkově mají obě skupiny odpovídající zastoupení ( $p > 0,1$ ), průměrný věk nemocných je 42,6 ( $\pm 9,7$ ) let a 32,9 ( $\pm 14,8$ ) let. Všichni jedinci s ataxií chůze trpí roztroušenou sklerózou, autoimunitním zánětlivým onemocněním poškozujícím centrální nervovou soustavu. Podmínkou zařazení pro nemocné jedince byla schopnost samostatné chůze bez kompenzačních pomůcek, přítomnost pohybového deficitu ve formě ataxie, absence jiných poruch majících vliv na stereotyp chůze (např. bolesti nosných kloubů a páteře).



Graf 1: Výška vyšetřovaných osob v cm a její rozdělení v obou sledovaných skupinách.

# AGE



Graf 2: Věk vyšetřovaných osob v letech a jeho rozdělení v obou sledovaných skupinách.



## **Parametrizace signálu**

**Kadence** - Počet kroků za minutu.

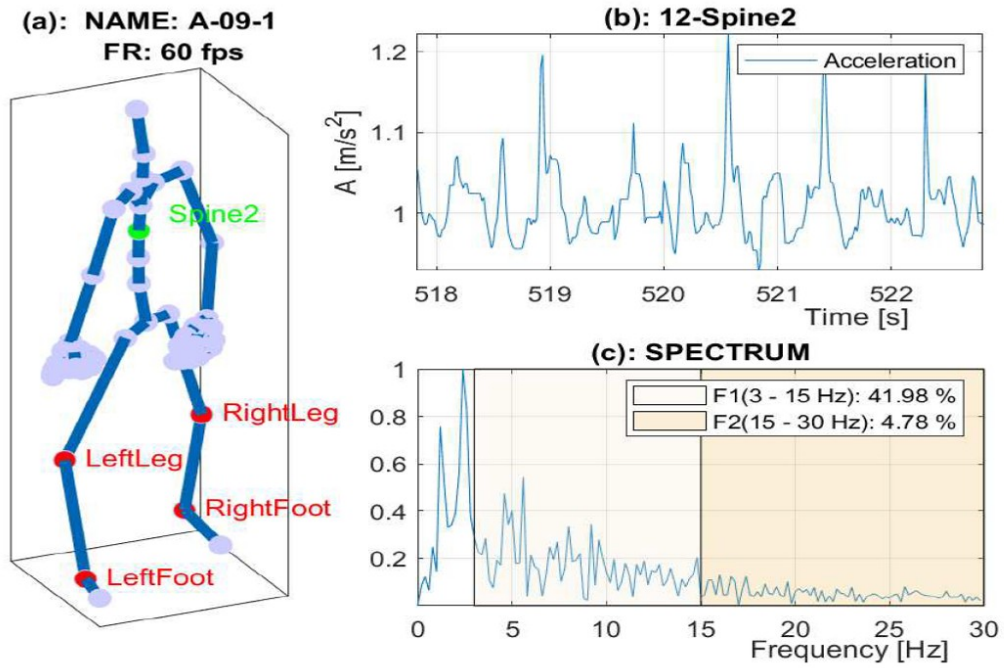
**Délka kroku a délka kroku vztažená k tělesné výšce** - Medián Eukleidovské vzdálenosti mezi následnými kontakty nohy s povrchem a jeho poměr k tělesné výšce.

**Délka trajektorie kroku a délka trajektorie kroku vztažená k tělesné výšce** - Medián délky trajektorie mezi následnými kontakty nohy s povrchem a její poměr k tělesné výšce.

**Relativní délka kroku a relativní délka kroku vztažená k tělesné výšce** - Poměr mezi délkou kroku a délkou trajektorie kroku a její poměr k tělesné výšce. Hodnota blíží se 1 indikuje optimální trajektorii kroku.

## **Směrodatná odchylka trajektorie těžiště**

**Energie signálu** - Akcelerometrická data jednotlivých segmentů byla transformována pomocí diskrétní Fourierovy transformace (DFT) do frekvenční domény. Maximální dosažitelná frekvence je při vzorkovací frekvenci senzoru 60 Hz je 29 Hz. Frekvence  $<0,3$ ) Hz jsou převážně šumem. Extrahovanými parametry byla relativní průměrná energie v pásmu  $<3, 15$ ) Hz a  $<15, 30$ ) Hz. Obr. 6 prezentuje princip současného snímání dat zařízením Perception neuron s 32 senzory lokalizovanými na různých částech těla a grafické znázornění výkonnostních spekter akcelerometrického signálu.

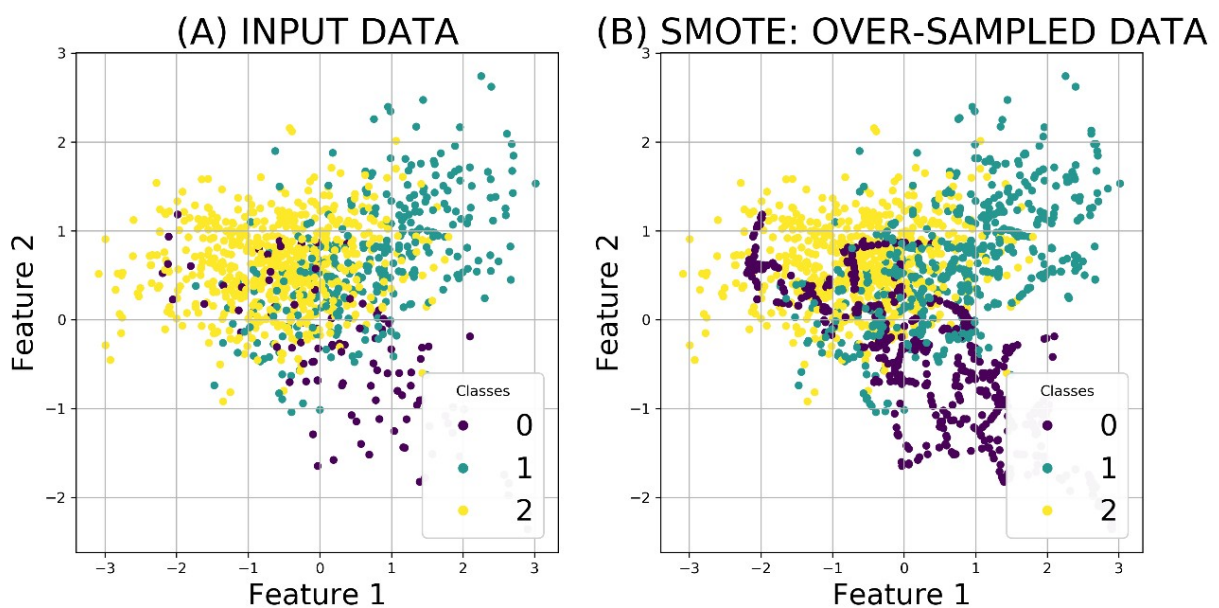


Obr. 6: Energie signálu. a) akcelerometrická data získaná pomocí senzoru z oblasti hrudní páteře, b) akcelerace v průběhu 5 s trvajícího segmentu rovné chůze, c) výkonostní spektrum 0-30 Hz při vzorkovací frekvenci 60 Hz, barevně jsou odlišené intervaly [3-15] a [15-30] Hz pro výpočet energie signálu ve frekvenčních pásmech

## Normalizace dat, balancování tříd a redukce dimenzionality

Ke škálování byla využita metoda normalizace podle z-skóre, kdy je odečtena průměrná hodnota a následně dělena směrodatnou odchylkou. K balancování tříd byla využita metoda SMOTE (Synthetic Minority Oversampling TEchnique).

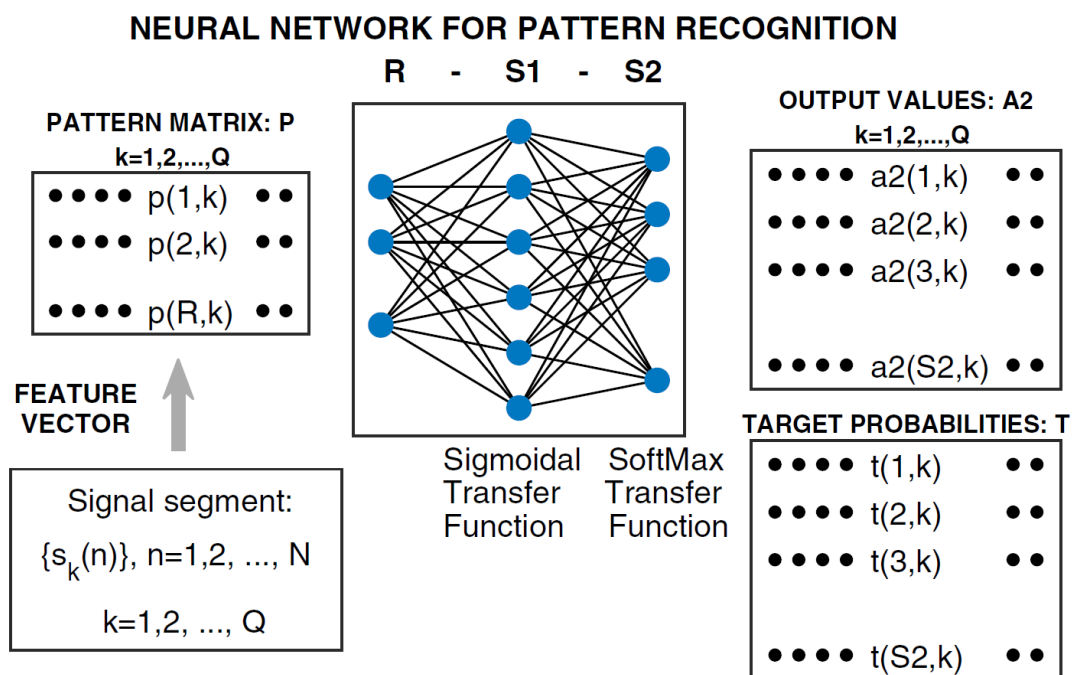
Porovnali jsme efekt třech metod redukujících dimensionalitu: t-Distributed Stochastic Neighbor Embedding (TSNE), Principal Component Analysis (PCA) a Uniform Manifold Approximation and Projection (UMAP).



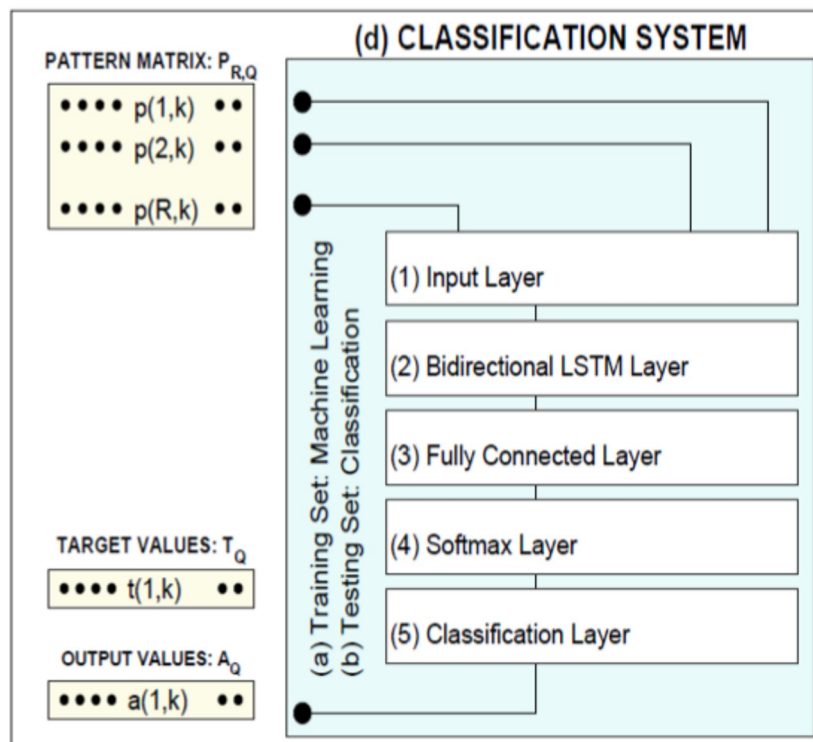
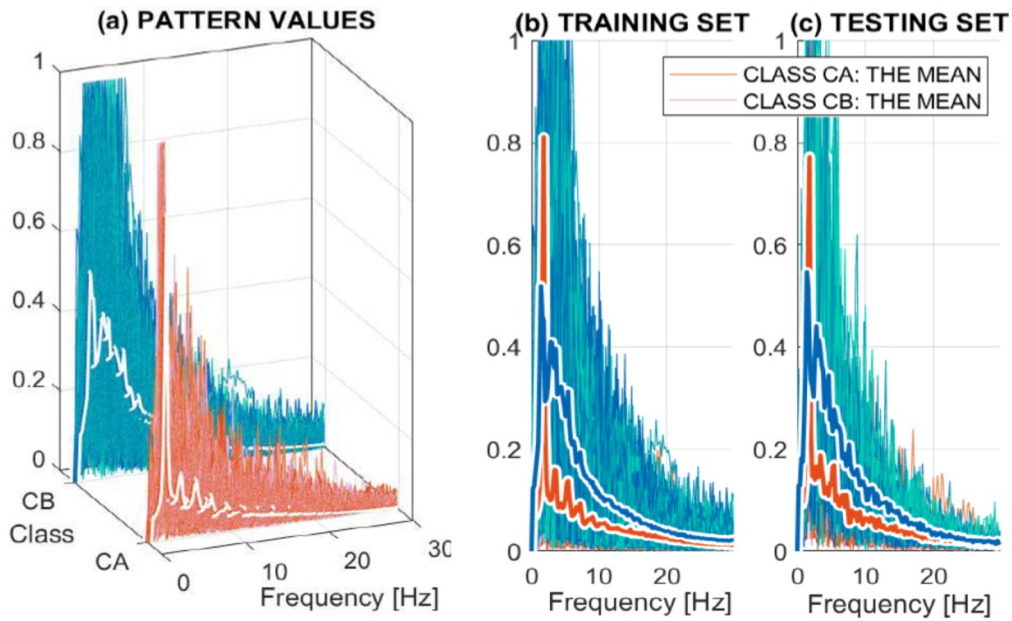
Graf 3: Balancování tříd technikou SMOTE (graf představuje balancování tříd ve třetí části)

## Klasifikace

Přítomnost ataxie chůze byla detekována následujícími mělkými klasifikátory: logistická regrese, support vector machine, naive Bayes, k-nearest neighbours, decision tree, random forest, adaboost, 2vrstvá neuronová síť (využívající sigmoidní transferové funkce v první vrstvě a softmax transferové funkce ve vrstvě druhé, obr. 7). Hluboká neuronová síť zahrnuje vstupní vrstvu, long short-term memory (LSMT) vrstvu, plně propojenou vrstvu, softmax vrstvu a klasifikační vrstvu (obr. 8).



Obr. 7: Schéma dvouvrstvé neuronové sítě se sigmoidní a softmax přenosovou funkcí k rozpoznání vlastností jednotlivých segmentů signálu akcelerometrických dat získaných ze specifických lokalizací na těle.



Obr.8.: Výběr parametrů získaných z jednotlivých segmentů chůze u skupiny s ataxií (modrá) a normy (červená). (a) spektrální komponenty jednotlivých segmentů a jejich průměrné hodnoty, (b) trénovací sada dat, (c) testovací sada dat vybraná náhodně ze všech získaných segmentů chůze, (d) zpracování dat pomocí hlubokého klasifikačního systému s pěti vrstvami využívající sloupcové vektory spektrálních komponent pro každý segment v matici vzorků (pattern matrix) a korespondující pravděpodobnosti náležitosti k jednotlivým třídám na výstupu.

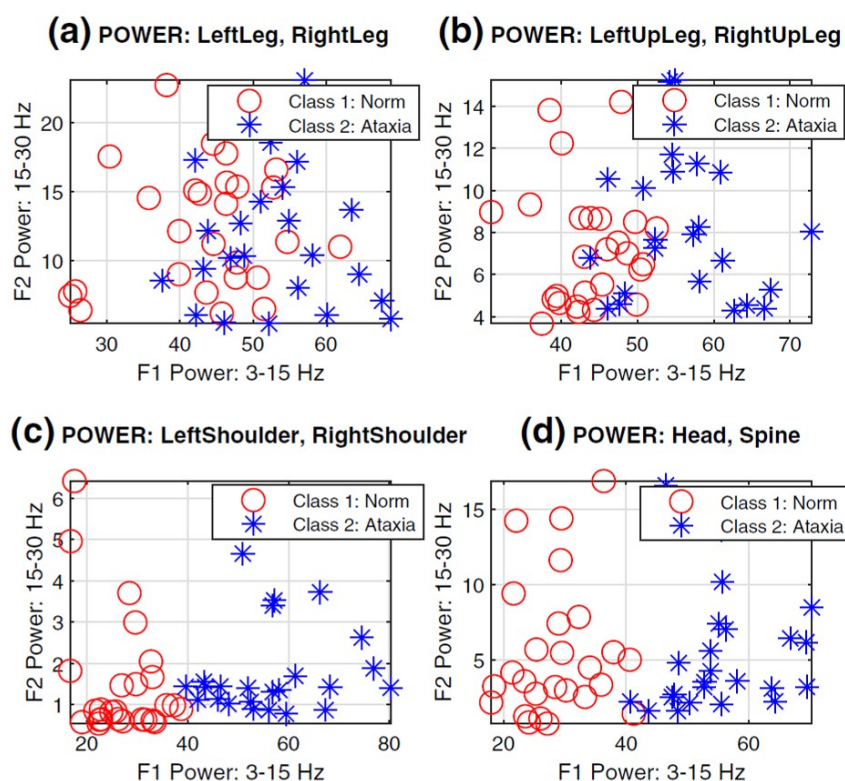
## Výsledky

### Část první

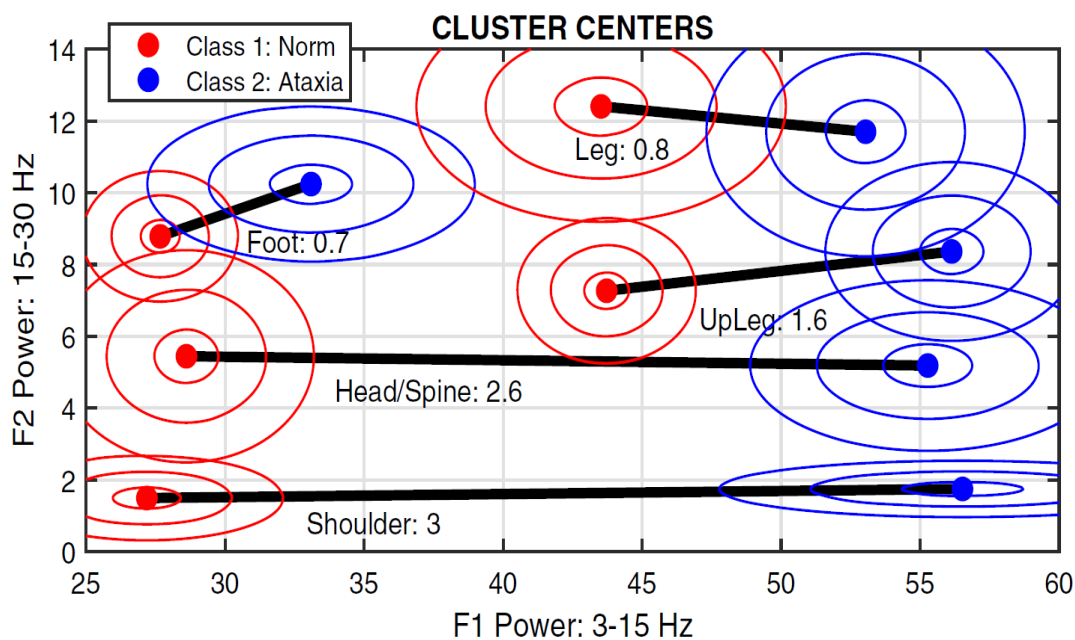
25 jedinců (tabulka 2) ze skupiny s ataxickou chůzí a zdravých kontrol bylo klasifikováno na základě průměrné energie signálu dvojice akcelerometrů umístěných na rozdílných částech těla. Shluky hodnot náležících skupině zdravých kontrol jsou kompaktnější než hodnoty náležící skupině s ataxií chůze, kde mají data větší směrodatnou odchylku (graf 4 a 5).

Třída	Počet jedinců	Počet segmentů
Norma	13	95
Ataxie	12	106
Celkem	25	201

Tab. 2: Počet sledovaných jedinců v jednotlivých skupinách a počet segmentů chůze délky 20 s.



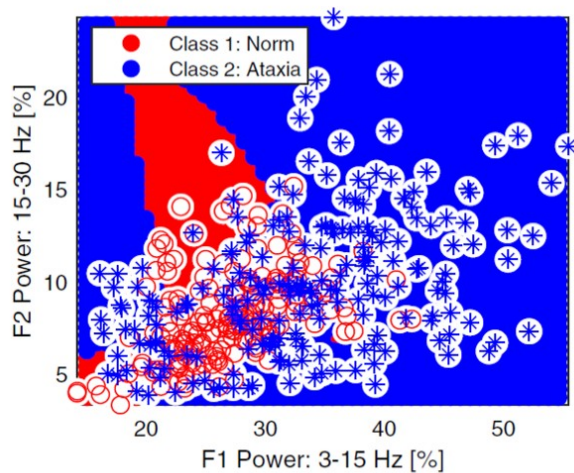
Graf. 4: Porovnání rozložení průměrné energie signálu u 25 testovaných jednotlivců. Akcelerometrická data získaná z pozice na nohách (a), stehnech (b), ramenou (c), hlavě a hrudní páteři (d). Jedinci s normální chůzí jsou označeni červeně a ataxičtí pacienti modře.



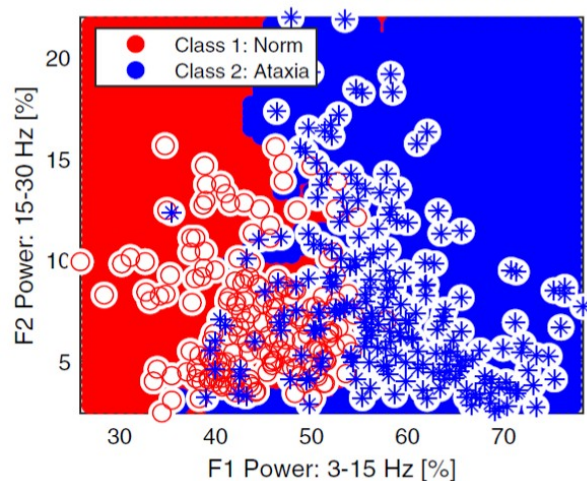
Graf 5: Rozložení center klastrů průměrné energie akcelerometrického signálu u 25 jedinců s ataxickou (modrá) a normální chůzí (červená). Vznačen je 0.2, 0.5 a 0.8 násobek směrodatné odchylky a hodnotu kritéria pro danou pozici senzoru.

Graf 6 porovnává vybrané výsledky klasifikace dvouvrstvou neuronovou sítí a zobrazuje distribuci frekvenčních vlastností signálu z levé nohy, levého stehna a levého ramene. Diskriminační schopnosti jsou vyšší pro senzory umístěné na horní polovině těla. Srovnání úspěšnosti klasifikace jednotlivých klasifikačních algoritmů, support vector machine, Bayesovská klasifikace, 3-nearest neighbour a dvouvrstvá neuronová síť, je uvedené v tabulce 3. Cross-validační chyba byla vyhodnocena metodou leave-one-out.

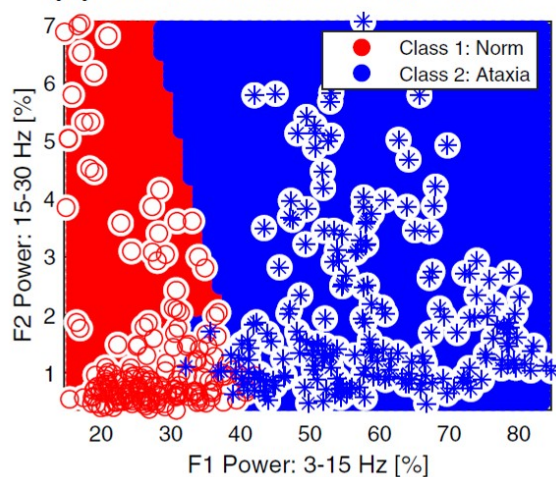
**(a) NN: FOOT / ACC:77.1, CV:0.253**



**(b) NN: UPLEG / ACC:89.9, CV:0.114**



**(c) NN: SHOULDER / ACC:98.0, CV:0.000**



Graf 6: Klasifikace frekvenčních parametrů dvourvrstvou neuronovou sítí pro pozici senzoru na a) levé noze, b) levém stehně, c) levém rameni. Červeně je označená skupina 1 – norma, modře skupina 2 – ataxie



Pozice	Metoda	ACC	TNR	TPR	CV
Levá/pravá noha	SVM	76,2	88,9	66,4	0,251
	Bayes'	67,9	80,5	55,2	0,326
	3-NN	75,3	86,8	83,9	0,289
	NN	78,1	87,4	69,8	0,246
Levá/pravá holeň	SVM	71,1	73,7	69,2	0,361
	Bayes'	70,1	66,8	73,1	0,306
	3-NN	79,3	80,5	82,1	0,346
	NN	78,9	66,1	81,6	0,264
Levé/pravé stehno	SVM	86,8	87,0	91,1	0,137
	Bayes'	85,6	87,9	83,5	0,144
	3-NN	89,8	91,1	88,7	0,182
	NN	89,9	93,6	84,1	0,114
Levé/pravé rameno	SVM	97,3	96,8	97,6	0,027
	Bayes'	97,0	97,4	96,7	0,030
	3-NN	97,0	98,4	95,8	0,047
	NN	97,6	97,9	97,2	0,012
Hlava/hrudní páteř	SVM	96,0	95,3	96,7	0,047
	Bayes'	93,5	93,2	93,9	0,067
	3-NN	96,8	96,8	96,7	0,047
	NN	98,5	98,4	97,6	0,035

Tab. 3: Přesnost (ACC [%]), specifická (TNR [%]), citlivost (TPR [%]), a cross-validační (CV) chyba klasifikace normální a ataxické chůze metodou support vector machine (SVM), Bayesovskou klasifikací, 3-nearest neighbour (3-NN) a dvouvrstvou neuronovou sítí (NN) v závislosti na pozici senzoru.

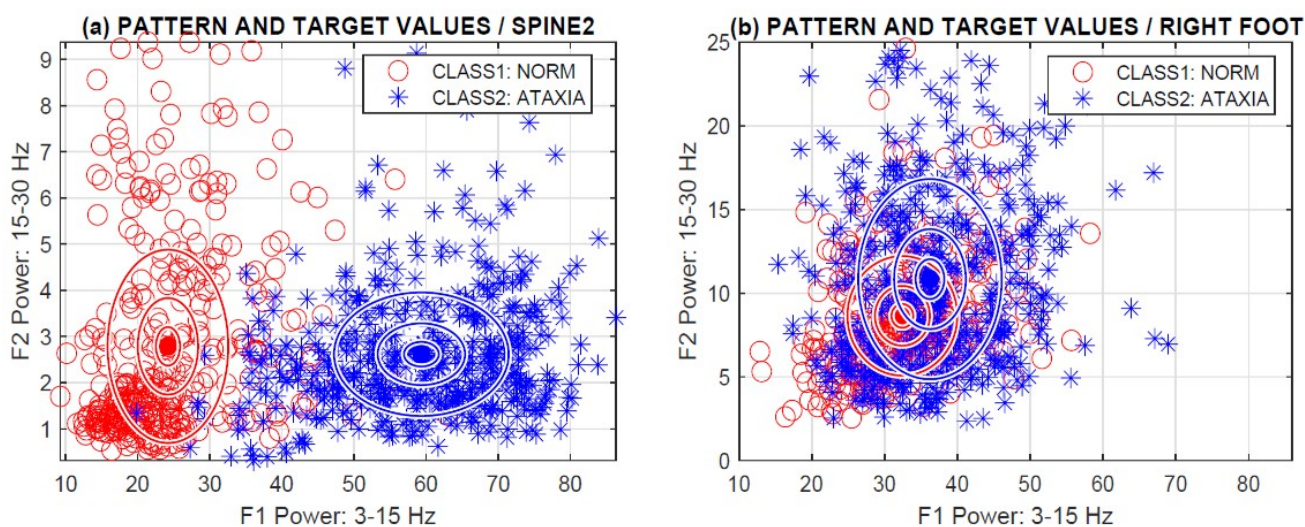
Přesnost klasifikace narůstá s výškou umístění senzoru (68 – 78 % pro nohy a 94 – 99 % pro hlavu a hrudní páteř). Rozdíly mezi jednotlivými klasifikátory jsou malé, nepatrně lepší úspěšnost vykazuje neuronová síť.

## Část druhá

36 jedinců (16 s ataxickou chůzí a 19 zdravých kontrol, tab. 4) se záznamy rozdělenými do 860 segmentů bylo klasifikováno pomocí hluboké neuronové sítě (DNN) a mělkých metod strojového učení na základě frekvenčních vlastností akcelerometrického signálu. Již z grafického rozložení hodnot parametrů je patrná snazší separovatelnost studovaných skupin při poloze senzoru na horní polovině těla (graf 7), což koresponduje s výsledky v první části.

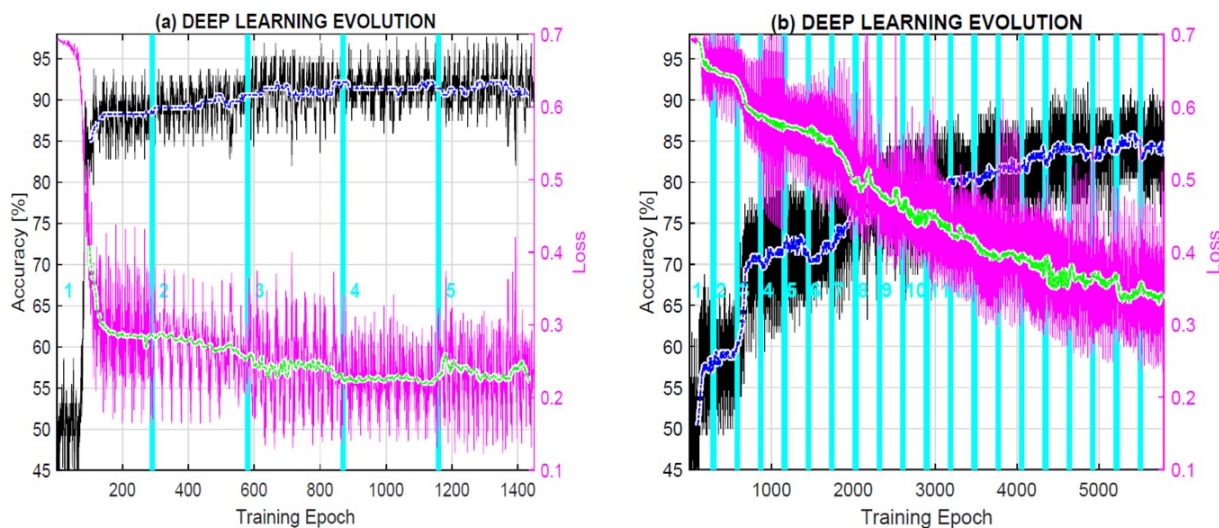
Třída	Počet jedinců	Počet segmentů
Norma	19	355
Ataxie	16	505
Celkem	35	860

Tab. 4: Počet sledovaných jedinců v jednotlivých skupinách a počet segmentů chůze délky 5 s.



Graf 7: Rozložení parametrů za využití energie signálu ve frekvenčním rozsahu  $< 15, 30$  ) Hz oproti energii signálu v rozsahu  $< 3, 15$  ) Hz s centry a c násobky směrodatné odchylky pro  $c = 0.2, c = 0.5, c = 1$ , pro pozici senzoru a) hrudní páteř a b) pravá noha.

Optimalizace DNN byla provedena v inkrementálním módu, což umožnilo modifikovat strukturu a koeficienty sítě během procesu učení. Optimalizační proces byl proveden v prostředí softwaru Matlab2020a. Graf 8 zobrazuje vývoj přesnosti a chyby (loss) během zvolených přírůstků fází učení hluboké sítě.




Graf 8.: Vývoj přesnosti a chyby při učení hluboké neuronové sítě pro pozici senzoru a) na hrudní páteři s konečnou přesností 92,2 % po 1400 epochách učení a b) na pravé noze s konečnou přesností 84,3 % po 6000 epochách učení.

Tabulka 5 obsahuje výsledky klasifikace pro dvě rozdílné pozice senzoru. Všechny testované klasifikační metody vykazují výrazně vyšší účinnost při vyhodnocení dat získaných z horní poloviny těla oproti dolním končetinám. SVM, Bayesovská metoda a dvouvrstvá NN vykazují velmi blízké výsledky s průměrnou přesností 94,8 % a 66,7% pro pozici na hrudní páteři a pravé noze s průměrnou cross-validační chybou 0,064 a 0,384 pro pozici na páteři a noze (graf 9). Přesnost hluboké neuronové sítě dosáhla 89,5 % pro pozici senzoru na hlavě a 81,2 % pro pozici na pravé noze. Nejvyšší přesnosti dosahuje DNN při kombinaci dat získaných z pozice na hrudní páteři a pravé noze současně a to 95,8% s chybou 0,09. Celkem 3 segmenty z celkového počtu 72 v testovacím souboru byly hlubokou neuronovou sítí zařazeny chybně. Lze očekávat, že s narůstajícím počtem senzorů se bude přesnost nadále zvyšovat, ačkoliv proces učení by trval déle.

Metoda	Hrudní páteř ACC [%]	Pravá noha ACC [%]
SVM	94,8	67,8
Bayes'	94,0	63,7
2vrstvá NN	95,2	68,6
DNN	89,0	81,2
DNN hrudní páteř + pravá noha		95,8

Tab. 5: Přesnost (ACC [%]) klasifikace normální a ataxické chůze metodou support vector machine (SVM), Bayesovskou klasifikací, dvouvrstvou neuronovou sítí (NN) a hlubokou neuronovou sítí (DNN). Srovnání přesnosti mezi polohou senzoru na hrudní páteři a pravé noze. Poslední řádek udává úspěšnost klasifikace DNN při kombinaci dat z nohy i páteře.



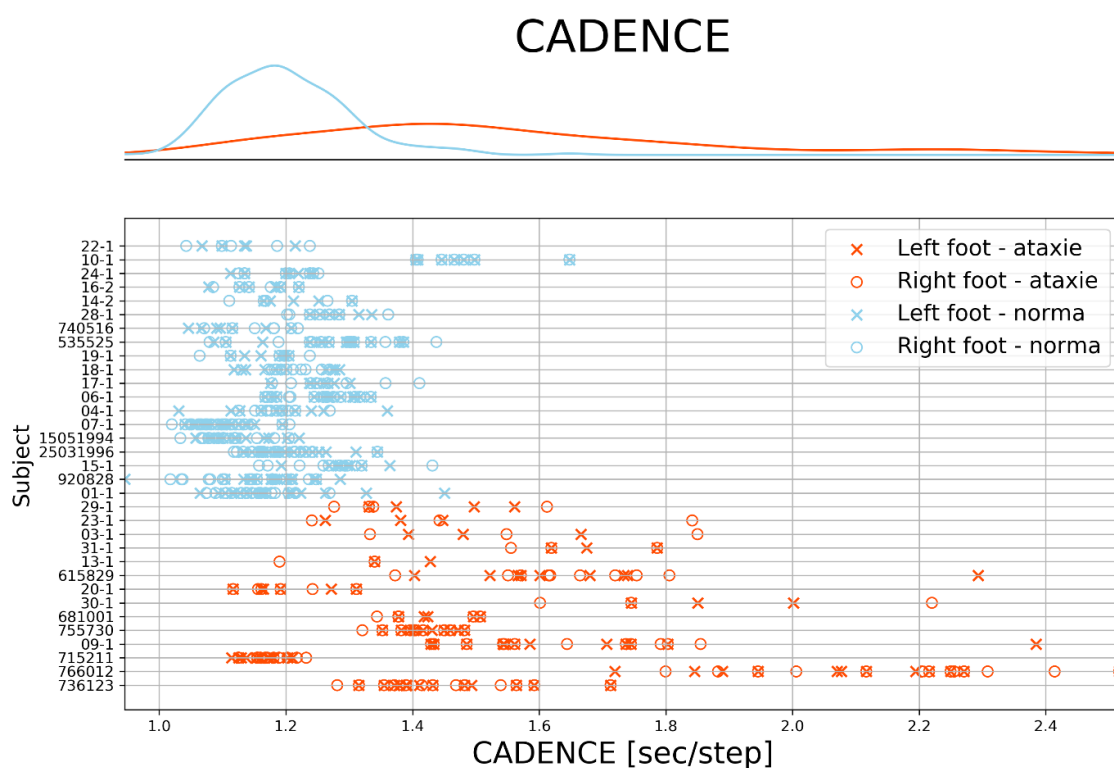
Graf 9: Klasifikace akcelerometrických dat podle dvou parametrů definovaných jako energie signálu ve dvou frekvenčních pásmech 3-15 a 15-30 Hz metodou a) SVM, b) Bayesovské metody, c) dvouvrstvé NN s přesností (AC [%]) a cross-validační (CV) chybou.

## Část třetí

Po automatické detekci segmentů chůze a parametrizaci signálu (grafy 10-16) jsme porovnali různé metody redukce dimenzionality dat a možnosti klasifikace redukovaných dat získaných záznamem chůze 33 účastníků (14 ataxických a 19 zdravých).


Principal component analysis (PCA) je nástroj který řadí prvky podle jejich eigenhodnot (eigenvalues), které korespondují se schopností diskriminace mezi jednotlivými třídami. Ze všech testovaných metod má nejhorší výsledky ve smyslu kategorizace jednotlivých subjektů (graf 17).

Uniform Manifold Approximation and Projection (UMAP) je metoda vhodná k predikci náležitosti nebo podobnosti nového vzorku k subjektu. Metoda T-Distributed Stochastic Neighbor Embedding (TSNE) zřetelně separuje jednotlivé skupiny, ale také viditelně shlukuje vzorky náležící jednomu subjektu (graf 18). Tíže ataxie chůze byla hodnocena dle klinické škály SARA, u sledovaných jedinců nabývá hodnot od 0 (norma) do 3 (těžká ataxie). Pomocí TSNE lze navíc dobře stratifikovat tíži ataxie (graf 19).



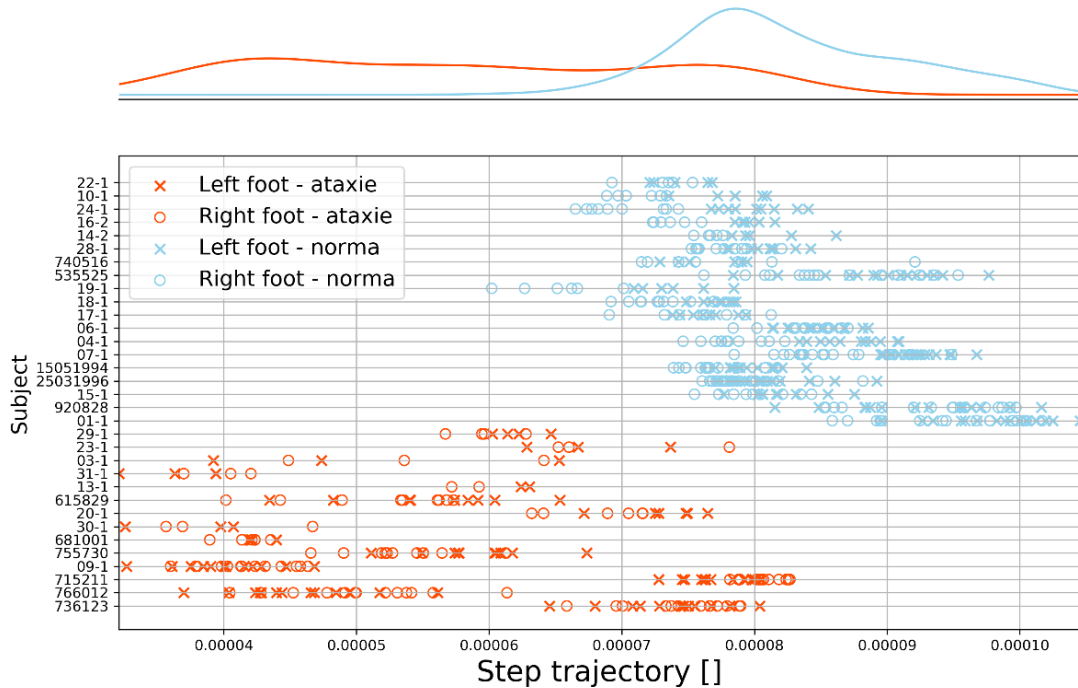
Graf 10: Kadence, počet kroků za sekundu a její rozložení v obou sledovaných skupinách.

## STEP LENGTH RELATIVE TO HEIGHT OF AN INDIVIDUAL



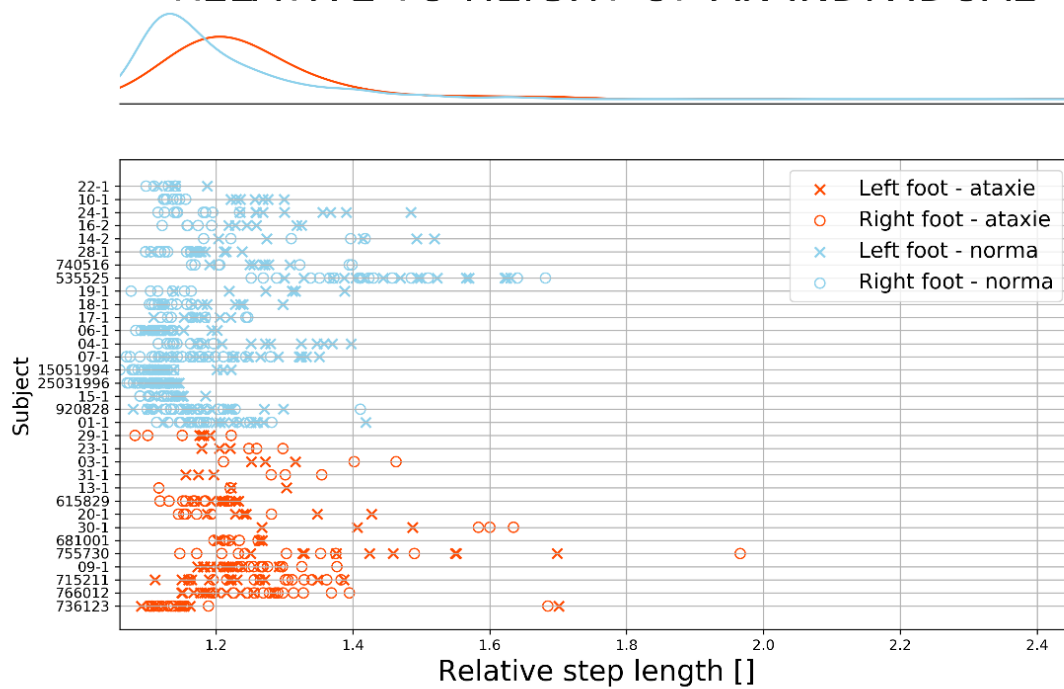
Graf 11: Délka kroku vztažená k tělesné výšce v obou sledovaných skupinách.

## STEP TRAJECTORY RELATIVE TO HEIGHT OF AN INDIVIDUAL



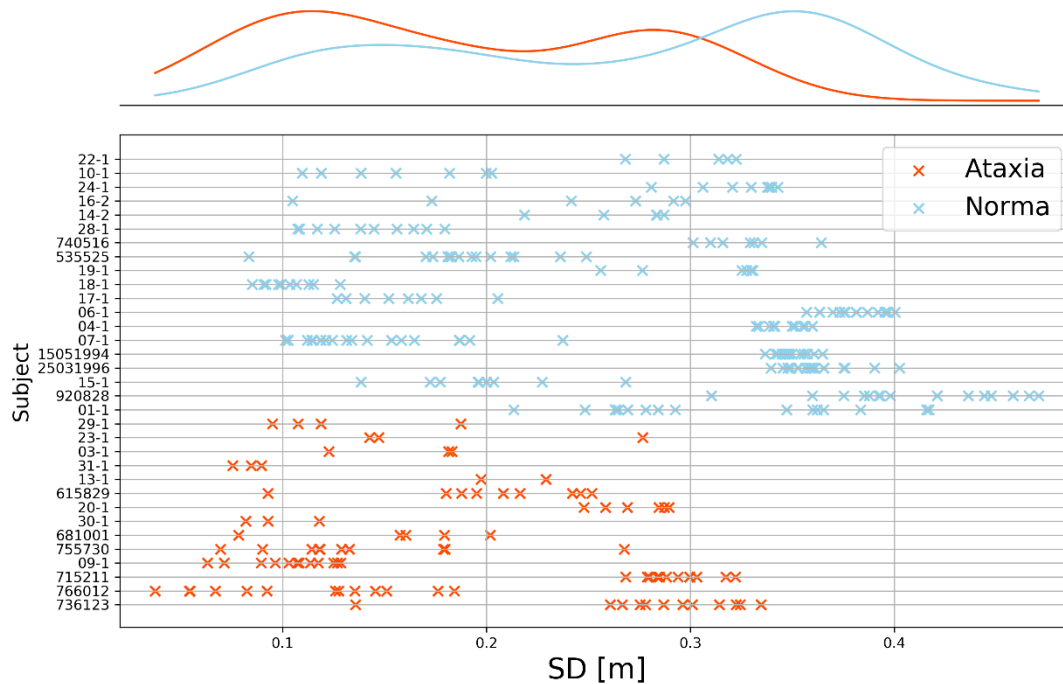
Graf 12: Trajektorie kroku vztažená k tělesné výšce v obou sledovaných skupinách.

## RELATIVE STEP LENGTH RELATIVE TO HEIGHT OF AN INDIVIDUAL



Graf 13: Relativní délka kroku vztažená k tělesné výšce v obou sledovaných skupinách.


## STANDARD DEVIATION OF COM MODULE



Graf 14: Směrodatná odchylka trajektorie těžiště.

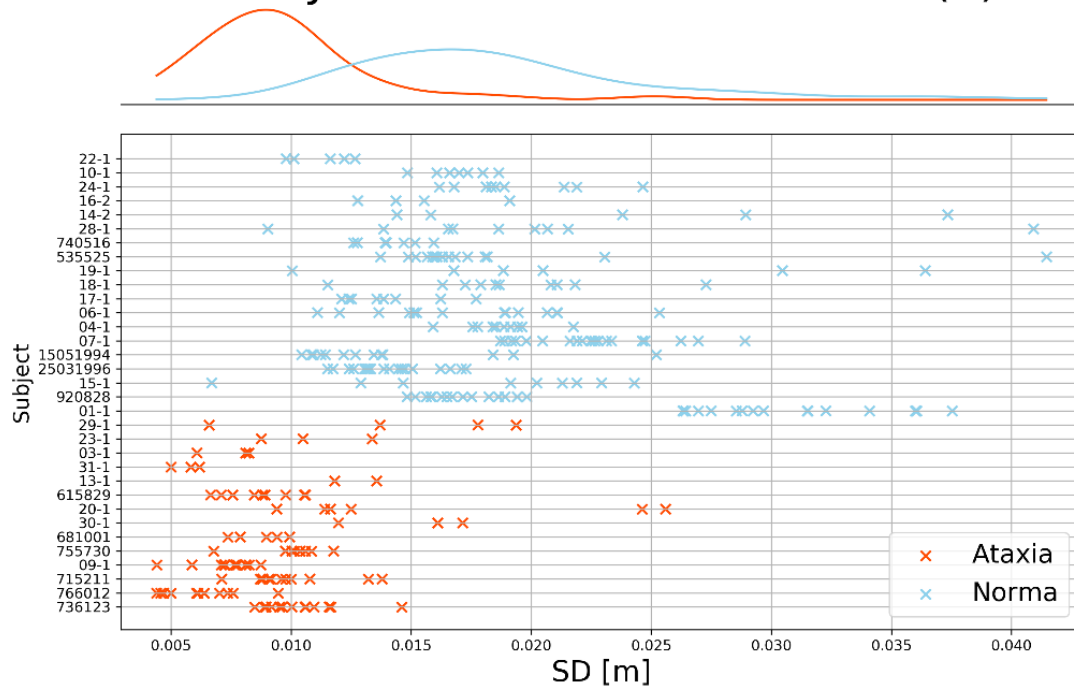


## STANDARD DEVIATION OF COM MODULE PROJECTED TO CORONAL PLANE (X)



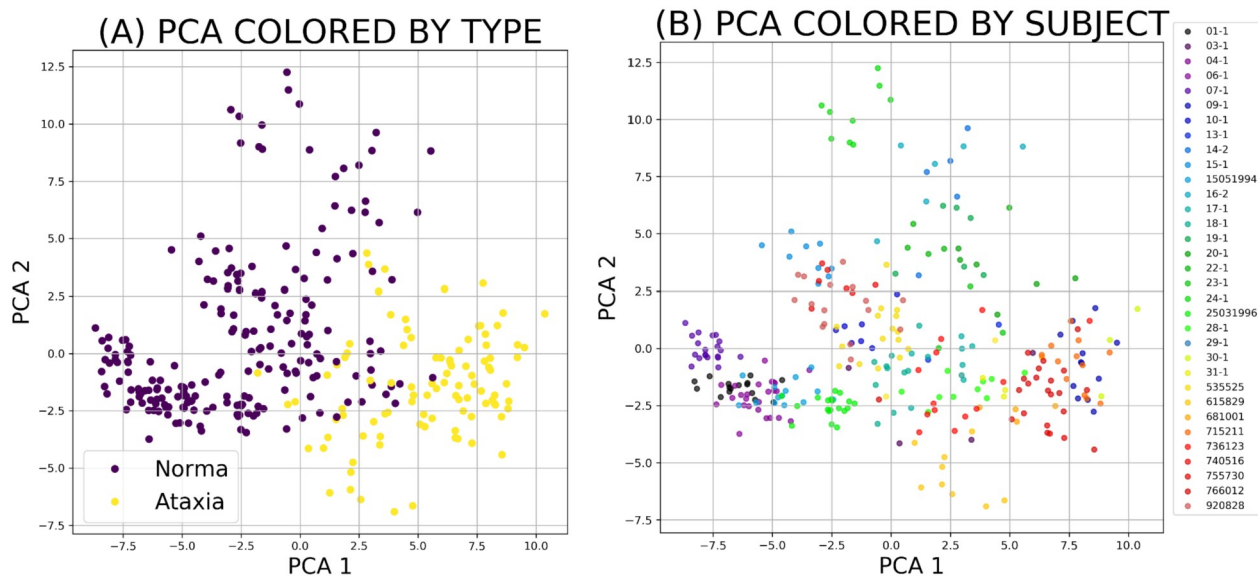
Graf 15: Směrodatná odchylka trajektorie těžiště v koronární rovině (x).

## STANDARD DEVIATION OF COM MODULE PROJECTED TO CORONAL PLANE (Z)

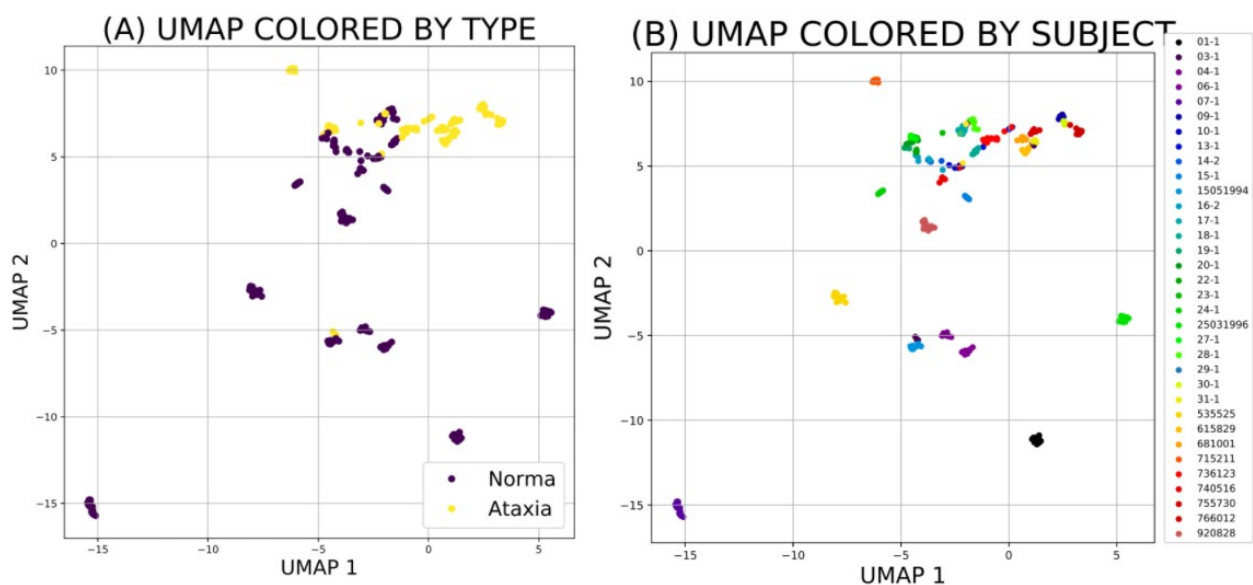


f 16: Směrodatná odchylka trajektorie těžiště v koronární rovině (y).

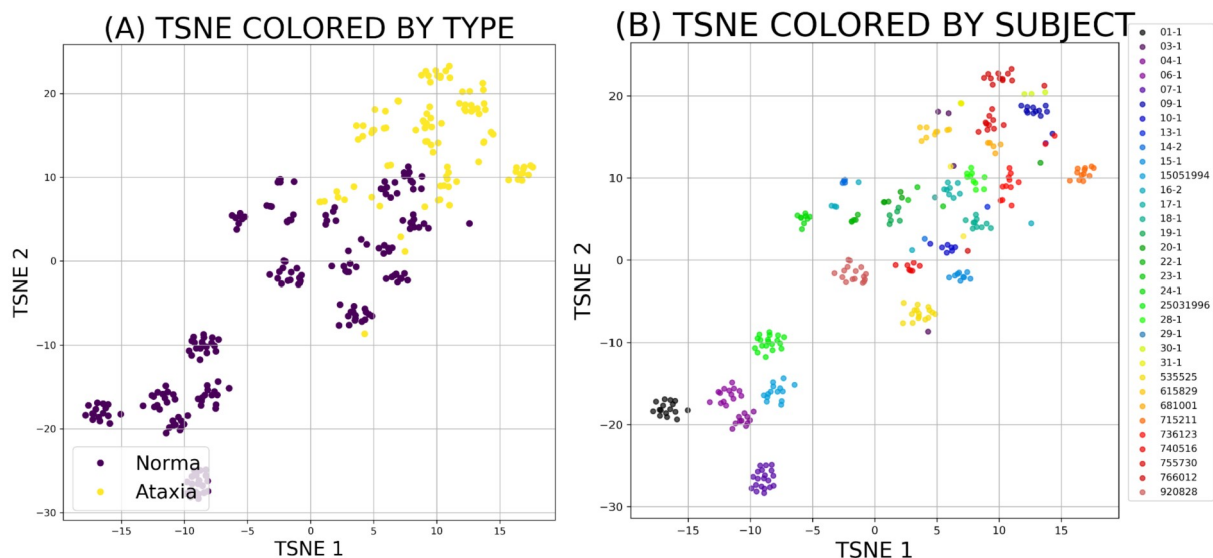
Gra




Graf 17: Redukce dat metodou principal component analysis (PCA). Barevně jsou rozlišeny a) skupina ataxie a norma, b) segmenty chůze náležící k jednotlivým subjektům.



Graf 18: Redukce dat metodou Uniform Manifold Approximation and Projection (UMAP). Barevně jsou rozlišeny a) skupina ataxie a norma, b) segmenty chůze náležící k jednotlivým subjektům.



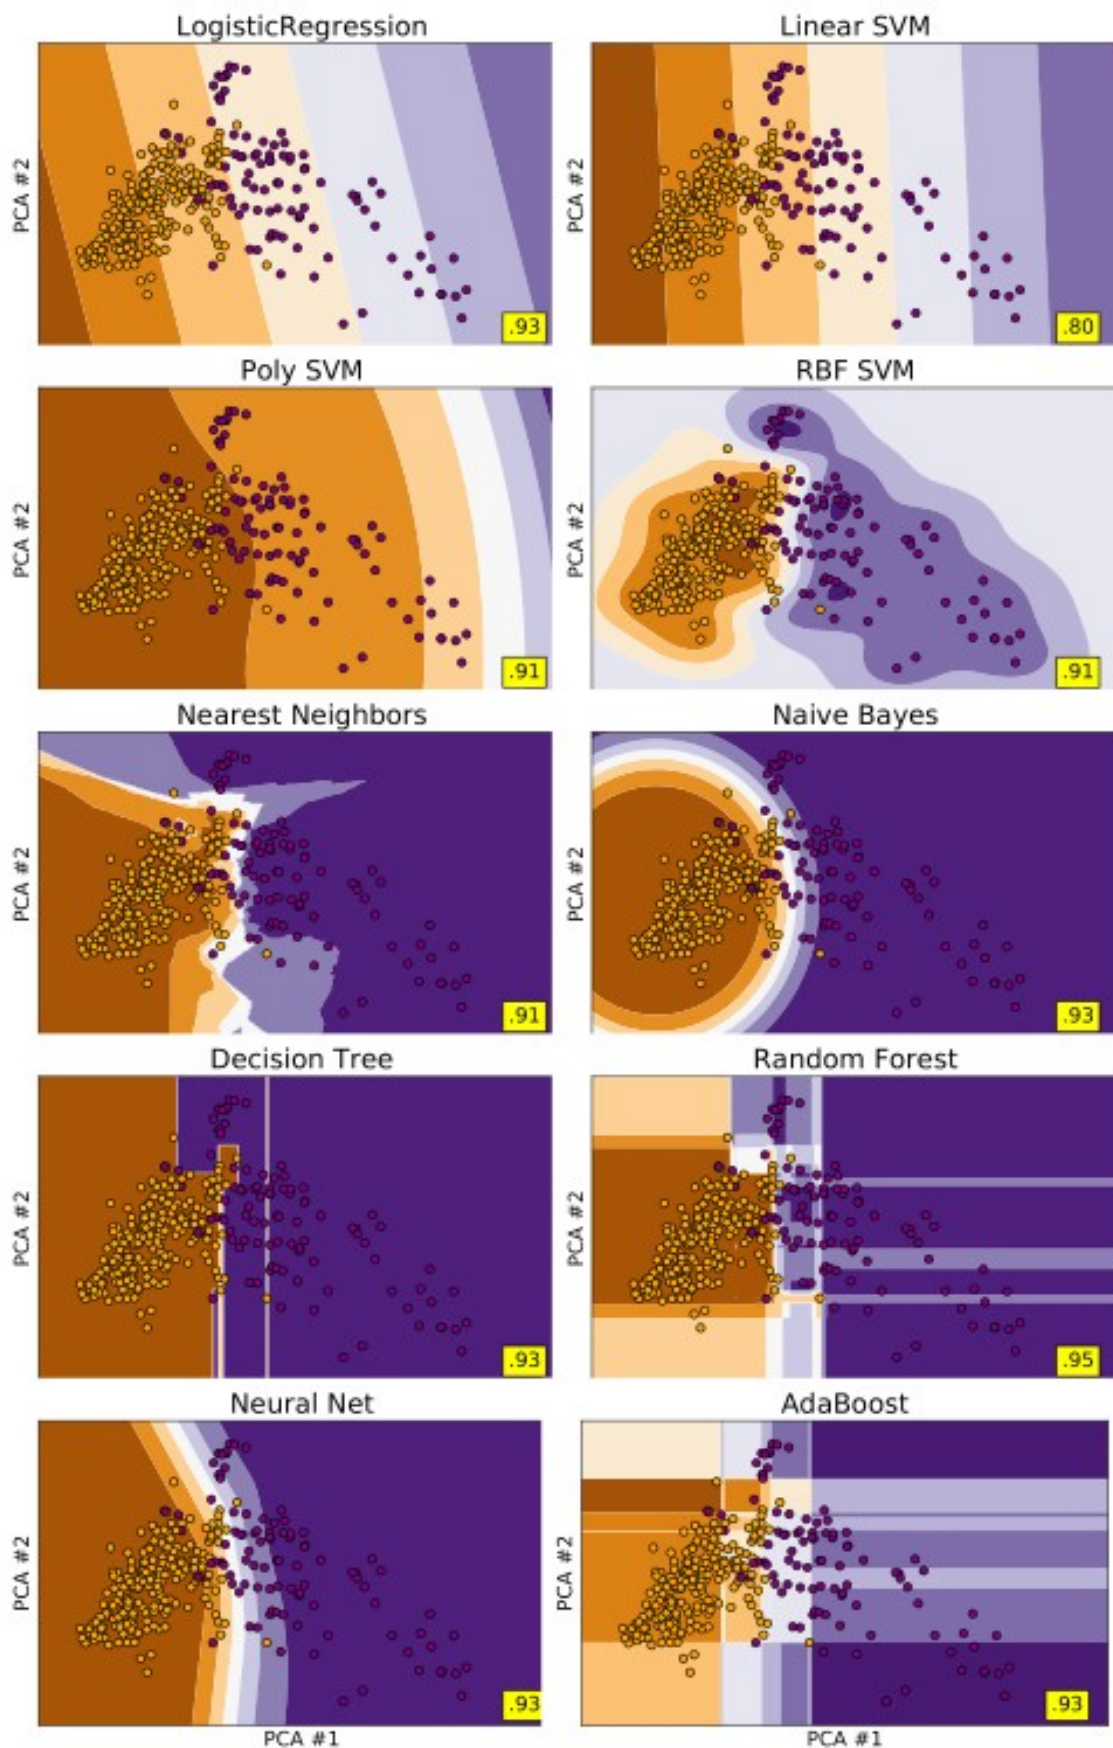
Graf 19: Redukce dat metodou T-Distributed Stochastic Neighbor Embedding (TSNE). Barevně jsou rozlišeny a) skupina ataxie a norma, b) segmenty chůze náležící k jednotlivým subjektům.



Graf 20: Redukce dat metodou PCA a TSNE, barevně je označena tíže ataxie hodnocená podle škály SARA.

Ze všech testovaných metod redukce dat a mělkých klasifikačních metod byla nejúspěšnější metoda random forest v kombinaci s TSNE s dosaženou přesností 98 %. V kombinaci s PCA dosáhl algoritmus random forest přesnosti 95 % a v kombinaci s UMAP pouze 92 %. Soubor grafů 20 názorně zobrazuje rozdělení jednotlivých skupin a úspěšnost klasifikace jednotlivých mělkých klasifikátorů.

Při hodnocení významnosti jednotlivých parametrů pro klasifikaci má největší význam energie signálu v pásmu 3-15 Hz v pozici hlavy, krční a hrudní páteře. Další významnou charakteristikou je délka a trajektorie kroku, a vertikální výchylka těžiště (výchylka v ose z).



Graf 21: Klasifikace jednotlivými mělkými klasifikátory po redukcí dat pomocí metody TSNE. Přesnost (ACC) klasifikace každé metody je uvedena ve žlutém poli.

## Diskuze

Metody strojového učení jsou běžně využívány k vyšetření abnormních chůzových vzorů pro jejich schopnost pracovat s vícerozměrnými nelineárními parametry. Otázka je, jakým způsobem ovlivňuje úspěšnost odhadu parametrů chůze. Vyšetření chůze založená na jiných technologických principech a často se vyskytující analýzy založené na časově-prostorových parametrech vykazují nižší přesnost.<sup>78,88,89</sup> Například analýzy ukazují, že není korelace mezi rychlostí chůze a tíhou postižení.<sup>90</sup> Detekce ataxie chůze pomocí mělkých klasifikátorů i hlubokých neuronových sítí založená na frekvenční analýze akcelerometrického signálu se jeví jako vysoce efektivní metoda.

Výsledky prezentované v této práci korespondují s výsledky publikovanými v poslední době. Měření horní části těla během chůze se jeví jako vysoce efektivní možnost, komplementární k analýze chůze pomocí krokových charakteristik. Představená metoda k rozlišení ataktické chůze je relativně jednoduchá a dostupná.

Frekvenční analýza signálu má vyšší uplatnění při využití dat ze senzorů umístěných na horní polovině těla.

Vysvětlením pro tento jev je pravděpodobně narušená schopnost pacientů s ataxií vyrovnávat náhlé výkyvy během chůze, což vede k abnormní reflexní odpovědi. Prvním mimovolním svalově-šlachovým reflexem je segmentální napínavý reflex *M1*, který se objevuje s krátkou latencí, obvykle méně než 50 ms. Následně lze registrovat tzv. „long loop“ reflex *M2*, s latencí 60 – 80 ms. Nakonec lze registrovat korektivní svalovou kontrakci *M3* antagonistických svalových skupin se zpožděním přibližně 100 ms. Jedinci s postižením mozečkem nebo spinocerebellárními dráhami mají opožděné *M2* a *M3* reflexy, navíc mají tyto jedinci silnější a delší odpověď antagonistů *M3*, což vede k přestřelení korekce a dalšímu odchýlení se od plánovaného pohybového programu.<sup>91,92</sup> Tento mimovolní jev podkladem pro mozečkový třes, který je charakteristický jeho nízkou frekvencí 3 – 7 Hz. Nepřesné a nekoordinované pohyby končetin a dysfunkční korekční reflexy vedou k oscilacím trupu. Tento jev je pravděpodobným vysvětlením pro vyšší energii vybraného frekvenčního pásma v rozmezí 3 – 15 Hz. S rostoucí vzdáleností od země roste amplituda výchylek, navíc dolní končetiny jsou během chůze částečně stabilizovány kontaktem se zemí, tento mechanismus je důvodem pro lepší výtěžnost dat ze senzorů umístěných na horní polovině těla.

Výhodou hlubokého učení je fakt, že nevyžaduje úvodní parametrizaci signálu, což je kompenzováno potřebou velmi rozsáhlých souborů dat, komplexní strukturou klasifikačního modelu a tím pádem vyššími nároky na výpočetní čas. U nemocných s těžší poruchou chůze není obvykle možné získat dostatečný objem dat, což může činit problém při učení některými typy hlubokých neuronových sítí. V těchto případech je možné využít mělké klasifikační metody. Výhodou standartních (mělkých) metod je snazší možnost vizualizace, jednoduchost klasifikačních modelů a rychlejší optimalizace jejich koeficientů. Vhodným řešením řady klasifikačních problémů je random forest. Kombinace jednotlivých náhodných stromů obchází nutnost normalizace proměnných, navíc obsahuje možnosti prevence chyby typu over-fitting a lze touto metodou porovnat význam jednotlivých parametrů pro výslednou klasifikaci. Kombinací mělkých i hlubokých metod lze pravděpodobně dosáhnout hlubšího porozumění fyzické podstaty studovaného systému.

Redukce dat metodou TSNE si oproti PCA zachovává nelineární vlastnosti. Ačkoliv metoda je metoda UMAP podobná TSNE, její horší výkonnost je způsobená nižší schopností separovat blízké klastry. TSNE metoda je vhodná k rozdělení subjektů podle tíže postižení.

## Závěr

Prezentovaná práce představuje možnosti využití akcelerometrů k detekci ataxie chůze při porovnání různých matematických metod zpracování signálu a klasifikace založené na strojovém učení.

Bylo prokázáno, že akcelerometrická data a jejich matematické zpracování frekvenční analýzou může být použito ke klasifikaci segmentů signálu do dvou kategorií reprezentovaných normální a ataxickou chůzí. Výsledky ukazují, jak může rozdílná poloha senzoru ovlivnit kvalitu klasifikace, její přesnost a cross-validační chybu. K detekci ataxie za využití frekvenčních komponent signálu je jednoznačně vhodnější pozice na horní polovině trupu oproti často využívaným pozicím na dolních končetinách, přesnost klasifikace se tak může navýšit až o 20 %. Všechny testované metody strojového učení vykazovali obdobně vysokou přesnost klasifikace. Při klasifikaci založené na frekvenční analýze dat z jednoho senzoru vykazovali nepatrně vyšší úspěšnost dvouvrstvá neuronová síť a support vector machine. Vyšší přesnost hlubokých neuronových sítí se uplatní při kombinaci dat z většího počtu senzorů. Jejich výhodou je možnost vynechání parametrizace dat, oproti tomu je nutné počítat s vysokými výpočetními nároky a potřebou větších objemů dat pro proces učení. Při využití většího množství parametrů a signálu z několika senzorů je vhodné aplikovat metody redukcující data, jako nejvhodnější z testovaných metod se jeví TSNE, která má nejlepší schopnost separace dat, což vede k vyšší úspěšnosti klasifikačních algoritmů. Navíc je pravděpodobné, že tato metoda umožní stratifikaci tíže onemocnění korespondující s klinickými škálami. Random forest se jeví jako vhodný nástroj v situaci s velkým množstvím vstupních parametrů, pravděpodobně pro jeho vlastnost vážení jejich významu.

Hlavní výhodou nositelných akcelerometrů oproti jiným zařízením ke sledování pohybu je možnost současného záznamu různých částí těla s relativně vysokým prostorově-časovým rozlišením a širokými možnostmi parametrizace dat.<sup>48,93-95</sup> Akcelerometry jsou snadno dostupné a pro jejich malé rozměry i dobře tolerované vyšetřovanými osobami.

Lidské tělo je komplexní systém jehož fungování je projevem složitých pochodů, které nelze popsat jednoduchými lineárními vztahy. Ve snaze o popis lidského pohybu se spoléháme na zjednodušené modely, klinická vyšetření a škály, které jsou zatížené lidskou chybou. S technickým rozvojem cenově dostupných, přenositelných senzorů schopných zaznamenávat pohyb s vysokou přesností se otevírá zcela nové pole objektivního sledování pohybových poruch s možností odhalení doposud



skrytých závislostí. Neinvazivní monitorace v přirozeném prostředí přinese možnosti přesnější diagnostiky, monitorace efektu léčby a včasné detekce zhoršení stavu. Již v současné době mají tyto metody uplatnění v některých odvětvích klinické praxe. V blízké budoucnosti lze očekávat zavedení biosenzorů coby komplementární metody k současným vyšetřovacím metodám. Podmínkou je však optimalizace výběru sledovaných parametrů, klasifikačních algoritmů a správná interpretace získaných výstupů.

## Autorovi práce k tématu

1. Dostál, O., Procházka, A., Vyšata, O. et al., "Recognition of motion patterns using accelerometers for ataxic gait assessment", *Neural Comput & Applic* 2020. IF 4.77 (2020)

Práce se zabývá automatickou detekcí ataxie chůze pomocí dat získaných za použití sady 31 akcelerometrů umístěných na různých částech těla. Záznamy získané od 14 jedinců byly rozděleny za 146 segmentů. Průměrná energie signálu ve frekvenčních pásmech 3-15 a 15-30 Hz sloužila jako parametr k následné klasifikaci jednotlivých segmentů. Support vector machine, dvouvrstvá neuronová síť, Nearest neighbour a Bayesovský klasifikátor vykazovaly srovnatelnou přesnost. Přesnost detekce ataxie při zvoleném parametru byla nejvyšší pro senzory umístěné na hlavě a ramenou - 99,6 % a 98,9 %, směrem k dolním končetinám se přesnost snižuje. Přesnost pro pozici na chodidlech, holeních a stehnech byla 80,9 %, 82,0 % a 90,6 %.

2. Procházka, A., Dostál, O., et al., "Deep Learning for Accelerometric Data Assessment and Ataxic Gait Monitoring", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021. IF 3.34 (2020)

Studie prezentující možnost využití akcelerometrických dat k optimalizaci učení konvoluční neuronové sítě k rozlišení mezi ataxickou a normální chůzí. Záznamy chůze 35 jedinců (16 s poruchou chůze a 19 norem) byly rozděleny na 860 segmentů. Komponenty frekvenční analýzy signálu sloužily jako vstupní data pro následnou klasifikaci pomocí Support vector machine, Bayesovských metod a 2vrstevných neuronových sítí. Z výsledků je patrné, že vhodný výběr pozice senzoru zvýší přesnost z 81,2 % pro pozici na chodidle na 91,7 % pro pozici na horní hrudní páteři. Kombinací dat ze dvou senzorů (horní hrudní páteř a chodidlo) a metod hlubokého učení hluboké s 5 vrstvami byla přesnost navýšena na 95,8%.

3. Dostál, O., Vyšata, O., et al., "Permutation Entropy and Signal Energy Increase the Accuracy of Neuropathic Change Detection in Needle EMG", *Computational Intelligence and Neuroscience*, 2018. IF 2.37 (2018)

Změny v motorických potenciálech svalu u pacientů s axonální neuropatií lze detekovat pomocí jehlové elektromyografie (EMG). Porovnány byly EMG záznamy 40 pacientů s polyneuropatií a 40

zdravých kontrol. Běžně rozšířená turns-amplitudová analýza rozšířená o energii signálu a permutační entropii představovali parametry k následné klasifikaci pomocí support vector machine. Výsledky prokazují vyšší úspěšnost klasifikace při využití kombinace všech výše uvedených parametrů oproti kombinacím s méně parametry. Kombinací permutační entropie, energie signálu a turns-amplitudové analýzy lze zpřesnit diagnostiku polyneuropatie pomocí elektromyografie.

4. Caisberger F, Vyšata O, Sedlák F, Dostál O, Kopal J, Procházka A, Kuchyňka J, Vališ M., "Outcome Prediction of Bell's Palsy by Kinect II", Biomed J Sci & Tech Res 14(5)-2019. BJSTR. MS.ID.002616.

Pět mimických svalů bylo testováno při volní kontrakci u pacientů s obrnou lícního nervu. Data byla nahrána pomocí „face tracking“ módu přístrojem Microsoft Kinect 2. Korespondující virtuální markery na obou stranách byly identifikovány během neutrálního výrazu obličeje s využitím afinního zobrazení. Podíl trajektorií. Podíl mezi trajektoriemi markerů na postižené a nepostižené straně obličeje představuje míru svalového postižení. K predikci vývoje pacientova stavu byla využita House-Brackmannova klinická škála a Hausdorffská a Eukleidovská vzdálenost při prvním a druhém vyšetření. Třetí vyšetření po 6 měsících sloužilo k posouzení výsledku. Nejvyšší přesnosti dosáhla House-Brackmannova škála (87 %), Hausdorffova vzdálenost 80 % a Eukleidovská vzdálenost 67 %. Nižší úspěšnost přisuzujeme nízké přesnosti hloubkového senzoru zařízení Kinect. Zavedení dalších parametrů popisujících symetrii, interpolaci v prostoru a čase a využití novějších 3D skenerů s vyšším rozlišením by mohlo zlepšit přesnost a reprodukovatelnost vyšetření.

5. Ondrej Dostal, Oldrich Vysata, Ladislav Pazdera, Martin Valis, "Wearable sensors for evaluation gait disorder in MS estimated by Learning Entropy", Neurology Apr 2019, 92 (15 Supplement) P3.2-019;

Detekce poruchy chůze zaznamenané pomocí sady 32 akcelerometrů s využitím entropie učení (learning entropy). Data získaná během chůze vykazují vysokou komplexitu. Za předpokladu deterministického chování systému, kde se nově získaná data řídí rozhodovacími zákony (governing laws) a nemohou tak nést žádnou novou informaci, jsme k detekci ataxie chůze využili entropii učení, což je metoda je adaptivní monitorace dynamických systémů. Predikovanou hodnotou byla délka trajektorie akcelerometru k následujícímu měření. Po výpočtu entropie z 31 senzorů, byla vy-

počtena její směrodatná odchylka a průměr. Algoritmus support vector machine balancovaný Bayesovskou optimalizací byl využit k rozlišení ataxické a normální chůze s přesností 79%.

6. Ondrej Dostal, Ondrej Tupa, Ales Prochazka, Oldrich Vysata, Ladislav Pazdera, Martin Valis, "The Best Motion Sensor Localization For Ataxic Gait Assessment", *Neurology* Apr 2020, 94 (15 Supplement) 1924;

Cílem práce je porovnání významu pozice senzorů a volby klasifikačního algoritmu s cílem detekovat ataxii chůze u pacientů s roztroušenou sklerózou. Nejvyšší přesnosti bylo dosaženo při využití senzoru na hlavě, krku a ramenou (až 99.6 %). Přesnost nejběžnějších klasifikátorů byla srovnatelná s maximálním rozdílem 1,8 %. Nejhorších výsledků bylo dosaženo při použití senzorů na nohách (65-88 %) a holeních (76-86 %). Vysoká přesnost dosažená senzory z horní poloviny těla je pravděpodobně zapříčiněná vzestupem poměru signálu a šumu. Šum je srovnatelný pro všechny senzory, kdežto amplituda kompenzačních oscilací narůstá se vzdáleností od země.

7. O. Āupa, O. Vyřata, A. Procházka, O. Dostál and M. Schätz, "Kinect V2 as a tool for stroke recovery: Pilot study of motion scale monitoring," 2016 International Workshop on Computational Intelligence for Multimedia Understanding (IWCIM), Reggio Calabria, 2016, pp. 1-5

Tato práce zkoumá aplikaci zařízení Kinect k monitoraci rehabilitace pacientů po cévní mozkové příhodě se zaměřením na měření prostorovou přesnost, tělesné propozice při úkolech dle zadání Motor assessment scale for stroke (MAS). Pomocí zařízení Kinect lze objektivně sledovat rozsahy pohybů během vyšetření. Technická limitace zvolené metody neumožňuje spolehlivě zaznamenat pohyb během všech úkolů, zejména otáčení se a vstávání z lehu a sledování pohybu ruky a prstů.

## Zdroje literatury

1. Český statistický úřad. *Statistiky* <https://www.czso.cz/csu/czso/statistiky>.
2. Lehnert, T., Heider, D. & Leicht, H. Review: Health Care Utilization and Costs of Elderly Persons With Multiple Chronic Conditions. *Med. Care Res. Rev.* (2011).
3. Aristotle. *On The Parts of Animals*.
4. Da Vinci, L. *The notebooks of Leonardo da Vinci*.
5. Borrelli, G. A. *On the Movement of Animals*.
6. *Human Motion: Understanding, Modelling, Capture, and Animation*. (Springer Netherlands, 2008). doi:10.1007/978-1-4020-6693-1.
7. Marson, F. A. L., Bertuzzo, C. S. & Ribeiro, J. D. Personalized or Precision Medicine? The Example of Cystic Fibrosis. *Front. Pharmacol.* **8**, (2017).
8. Ho, D. *et al.* Enabling Technologies for Personalized and Precision Medicine. *Trends in Biotechnology* **38**, 497–518 (2020).
9. Jain, S., Lo, S. E. & Louis, E. D. Common Misdiagnosis of a Common Neurological Disorder: How Are We Misdiagnosing Essential Tremor? *Arch Neurol* **63**, 1100 (2006).
10. Rovini, E., Maremmani, C. & Cavallo, F. How Wearable Sensors Can Support Parkinson's Disease Diagnosis and Treatment: A Systematic Review. *Front. Neurosci.* **11**, (2017).
11. Zaidi, A., Clough, P., Cooper, P., Scheepers, B. & Fitzpatrick, A. P. Misdiagnosis of epilepsy: many seizure-like attacks have a cardiovascular cause. *Journal of the American College of Cardiology* **36**, 181–184 (2000).
12. Godoi, B. B. *et al.* Parkinson's disease and wearable devices, new perspectives for a public health issue: an integrative literature review. *Revista da Associação Médica Brasileira* **65**, 1413–1420 (2019).

13. Lee, J.-Y. *et al.* Feasibility, reliability, and validity of using accelerometers to measure physical activities of patients with stroke during inpatient rehabilitation. *PLOS ONE* **13**, e0209607 (2018).
14. Henderson, E. J. *et al.* Rivastigmine for gait stability in patients with Parkinson's disease (ReSPonD): a randomised, double-blind, placebo-controlled, phase 2 trial. *The Lancet Neurology* **15**, 249–258 (2016).
15. Heldman, D. A., Espay, A. J., LeWitt, P. A. & Giuffrida, J. P. Clinician versus machine: Reliability and responsiveness of motor endpoints in Parkinson's disease. *Parkinsonism & Related Disorders* **20**, 590–595 (2014).
16. Angelini, L. *et al.* Is a Wearable Sensor-Based Characterisation of Gait Robust Enough to Overcome Differences Between Measurement Protocols? A Multi-Centric Pragmatic Study in Patients with Multiple Sclerosis. *Sensors* **20**, 79 (2020).
17. Spain, R. I. *et al.* Body-worn motion sensors detect balance and gait deficits in people with multiple sclerosis who have normal walking speed. *Gait Posture* **35**, 573–578 (2012).
18. Carpinella, I., Cattaneo, D. & Ferrarin, M. Quantitative assessment of upper limb motor function in Multiple Sclerosis using an instrumented Action Research Arm Test. *Journal of NeuroEngineering and Rehabilitation* **11**, 67 (2014).
19. Greene, B. R. *et al.* Longitudinal assessment of falls in patients with Parkinson's disease using inertial sensors and the Timed Up and Go test. *Journal of Rehabilitation and Assistive Technologies Engineering* **5**, 2055668317750811 (2018).
20. Reif, M. Hodnotící škály používané u pacientů s cévní mozkovou příhodou. *Neurol. praxi* 12–15 (2011).
21. Ehler, E. Spasticita - klinické škály. *Neurol. praxi* **2015**, 20–23.

22. Cedarbaum, J. M. & Stambler, N. Performance of the Amyotrophic Lateral Sclerosis Functional Rating Scale (ALSFRS) in multicenter clinical trials. *Journal of the Neurological Sciences* **152**, s1–s9 (1997).
23. Lyle, R. C. A performance test for assessment of upper limb function in physical rehabilitation treatment and research. *International Journal of Rehabilitation Research* **4**, 483–492 (1981).
24. Prada, V. *et al.* Mam36 and Abilhand as outcome measures of multiple sclerosis hand disability: an observational study. *Eur J Phys Rehabil Med* (2020) doi:10.23736/S1973-9087.20.06446-1.
25. Earhart, G. M. *et al.* The 9-hole PEG test of upper extremity function: average values, test-retest reliability, and factors contributing to performance in people with Parkinson disease. *J Neurol Phys Ther* **35**, 157–163 (2011).
26. Goldman, M. D. *et al.* Clinically meaningful performance benchmarks in MS: Timed 25-Foot Walk and the real world. *Neurology* **81**, 1856–1863 (2013).
27. Kurtzke, J. F. Rating neurologic impairment in multiple sclerosis: An expanded disability status scale (EDSS). *Neurology* **33**, 1444–1444 (1983).
28. Goetz, C. G. *et al.* Movement Disorder Society-sponsored revision of the Unified Parkinson's Disease Rating Scale (MDS-UPDRS): Scale presentation and clinimetric testing results. *Movement Disorders* **23**, 2129–2170 (2008).
29. Goetz, C. G. *et al.* Movement Disorder Society Task Force report on the Hoehn and Yahr staging scale: Status and recommendations The Movement Disorder Society Task Force on rating scales for Parkinson's disease. *Movement Disorders* **19**, 1020–1028 (2004).
30. Gladstone, D. J., Danells, C. J. & Black, S. E. The Fugl-Meyer Assessment of Motor Recovery after Stroke: A Critical Review of Its Measurement Properties. *Neurorehabil Neural Repair* **16**, 232–240 (2002).

31. Yabe, I., Matsushima, M., Soma, H., Basri, R. & Sasaki, H. Usefulness of the Scale for Assessment and Rating of Ataxia (SARA). *Journal of the Neurological Sciences* **266**, 164–166 (2008).
32. Ramsey, D. *et al.* Revised Hammersmith Scale for spinal muscular atrophy: A SMA specific clinical outcome assessment tool. *PLoS One* **12**, e0172346 (2017).
33. Jarchi, D. *et al.* A Review on Accelerometry-Based Gait Analysis and Emerging Clinical Applications. *IEEE Reviews in Biomedical Engineering* **11**, 177–194 (2018).
34. *Optical Magnetometry*. (Cambridge University Press, 2013). doi:10.1017/CBO9780511846380.
35. Donno, M., Palange, E., Nicola, F. D., Bucci, G. & Ciancetta, F. A New Flexible Optical Fiber Goniometer for Dynamic Angular Measurements: Application to Human Joint Movement Monitoring. *IEEE Transactions on Instrumentation and Measurement* **57**, 1614–1620 (2008).
36. Pourmoghaddam, A., Dettmer, M., O'Connor, D. P., Paloski, W. H. & Layne, C. S. Identification of Changing Lower Limb Neuromuscular Activation in Parkinson's Disease during Treadmill Gait with and without Levodopa Using a Nonlinear Analysis Index. *Parkinsons Dis* **2015**, 497825 (2015).
37. Topley, M. & Richards, J. G. A comparison of currently available optoelectronic motion capture systems. *Journal of Biomechanics* **106**, 109820 (2020).
38. Procházka, A. *et al.* Bayesian classification and analysis of gait disorders using image and depth sensors of Microsoft Kinect. *Digital Signal Processing* **47**, 169–177 (2015).
39. Ľupa, O. *et al.* Motion tracking and gait feature estimation for recognising Parkinson's disease using MS Kinect. *BioMedical Engineering OnLine* **14**, 97 (2015).
40. Byun, S., Han, J. W., Kim, T. H. & Kim, K. W. Test-Retest Reliability and Concurrent Validity of a Single Tri-Axial Accelerometer-Based Gait Analysis in Older Adults with Normal Cognition. *PLOS ONE* **11**, e0158956 (2016).



41. Din, S. D., Godfrey, A. & Rochester, L. Validation of an Accelerometer to Quantify a Comprehensive Battery of Gait Characteristics in Healthy Older Adults and Parkinson's Disease: Toward Clinical and at Home Use. *IEEE Journal of Biomedical and Health Informatics* **20**, 838–847 (2016).
42. Rehman, R. Z. U. *et al.* Comparison of Walking Protocols and Gait Assessment Systems for Machine Learning-Based Classification of Parkinson's Disease. *Sensors* **19**, 5363 (2019).
43. Lin, F., Wang, A., Zhuang, Y., Tomita, M. R. & Xu, W. Smart Insole: A Wearable Sensor Device for Unobtrusive Gait Monitoring in Daily Life. *IEEE Transactions on Industrial Informatics* **12**, 2281–2291 (2016).
44. Malvade, P. S., Joshi, A. K. & Madhe, S. P. In-sole Shoe Foot Pressure Monitoring for Gait Analysis. in *2017 International Conference on Computing, Communication, Control and Automation (ICCUBEA)* 1–4 (2017). doi:10.1109/ICCUBEA.2017.8463769.
45. Smith Michael T. *et al.* Use of Actigraphy for the Evaluation of Sleep Disorders and Circadian Rhythm Sleep-Wake Disorders: An American Academy of Sleep Medicine Systematic Review, Meta-Analysis, and GRADE Assessment. *Journal of Clinical Sleep Medicine* **14**, 1209–1230.
46. Chitnis, T. *et al.* Quantifying neurologic disease using biosensor measurements in-clinic and in free-living settings in multiple sclerosis. *npj Digital Medicine* **2**, 1–8 (2019).
47. Ashhar, K., Soh, C. B. & Kong, K. H. Wireless Ultrawideband Sensor Network for Gait Analysis in Rehabilitation Clinics. in *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* 1524–1529 (2018). doi:10.1109/SMC.2018.00264.
48. Zilani, T. A., Al-Turjman, F., Khan, M. B., Zhao, N. & Yang, X. Monitoring Movements of Ataxia Patient by Using UWB Technology. *Sensors* **20**, 931 (2020).
49. Procházka, A. *et al.* Remote physiological and GPS data processing in evaluation of physical activities. *Med Biol Eng Comput* **52**, 301–308 (2014).

50. Li, Y. *et al.* Motor Function Evaluation of Hemiplegic Upper-Extremities Using Data Fusion from Wearable Inertial and Surface EMG Sensors. *Sensors* **17**, 582 (2017).
51. Perry, J. *Gait analysis: normal and pathological function.* (SLACK, 1992).
52. McGrath, M., Howard, D. & Baker, R. The strengths and weaknesses of inverted pendulum models of human walking. *Gait & Posture* **41**, 389–394 (2015).
53. Bellanca, J. L., Lowry, K. A., VanSwearingen, J. M., Brach, J. S. & Redfern, M. S. Harmonic ratios: A quantification of step to step symmetry. *Journal of Biomechanics* **46**, 828–831 (2013).
54. Phan, D. *et al.* A Random Forest Approach for Quantifying Gait Ataxia With Truncal and Peripheral Measurements Using Multiple Wearable Sensors. *IEEE Sensors Journal* **20**, 723–734 (2020).
55. Dostál, O. *et al.* Recognition of motion patterns using accelerometers for ataxic gait assessment. *Neural Comput & Applic* (2020) doi:10.1007/s00521-020-05103-2.
56. Kashyap, B. *et al.* Objective Assessment of Cerebellar Ataxia: A Comprehensive and Refined Approach. *Scientific Reports* **10**, 9493 (2020).
57. Nguyen, N. *et al.* Quantification of Axial Abnormality Due to Cerebellar Ataxia with Inertial Measurements. *Sensors* **18**, 2791 (2018).
58. Richman, J. S. & Moorman, J. R. Physiological time-series analysis using approximate entropy and sample entropy. *American Journal of Physiology-Heart and Circulatory Physiology* **278**, H2039–H2049 (2000).
59. Procházka, A., Vyšata, O., Charvátová, H. & Vališ, M. Motion Symmetry Evaluation Using Accelerometers and Energy Distribution. *Symmetry* **11**, 871 (2019).
60. Ghislieri, M., Gastaldi, L., Pastorelli, S., Tadano, S. & Agostini, V. Wearable Inertial Sensors to Assess Standing Balance: A Systematic Review. *Sensors* **19**, 4075 (2019).
61. Amici, C. *et al.* Multi-Sensor Validation Approach of an End-Effector-Based Robot for the Rehabilitation of the Upper and Lower Limb. *Electronics* **9**, 1751 (2020).

62. San-Segundo, R. *et al.* Parkinson's Disease Tremor Detection in the Wild Using Wearable Accelerometers. *Sensors* **20**, 5817 (2020).
63. Sharma, B. M., Vidhya, S. & Kumar, N. System for measurement of joint range of motion using inertial sensors. *Biomedical Research* **28**, (2017).
64. Singh, D. & Singh, B. Investigating the impact of data normalization on classification performance. *Applied Soft Computing* **97**, 105524 (2020).
65. More, A. Survey of resampling techniques for improving classification performance in unbalanced datasets. *arXiv:1608.06048 [cs, stat]* (2016).
66. van der Maaten, L., Postma, E. & Herik, H. Dimensionality Reduction: A Comparative Review. *Journal of Machine Learning Research - JMLR* **10**, (2007).
67. Dimensionality Reduction Techniques | Python. *Analytics Vidhya*  
<https://www.analyticsvidhya.com/blog/2018/08/dimensionality-reduction-techniques-python/> (2018).
68. Hastie, T., Tibshirani, R. & Friedman, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition*. (Springer-Verlag, 2009). doi:10.1007/978-0-387-84858-7.
69. Schölkopf, B. & Smola, A. J. *Smola, A.: Learning with Kernels - Support Vector Machines, Regularization, Optimization and Beyond*. MIT Press, Cambridge, MA. *Journal of The American Statistical Association - J AMER STATIST ASSN* vol. 98 (2001).
70. Zou, J., Han, Y. & So, S.-S. Overview of Artificial Neural Networks. in *Artificial Neural Networks: Methods and Applications* (ed. Livingstone, D. J.) 14–22 (Humana Press, 2009). doi:10.1007/978-1-60327-101-1\_2.
71. Hong, P., Chengde, L., Linkai, L. & Qifeng, Z. Accuracy of Classifier Combining Based on Majority Voting. in *2007 IEEE International Conference on Control and Automation* 2654–2658 (2007). doi:10.1109/ICCA.2007.4376843.

72. Tharwat, A. Classification assessment methods. *Applied Computing and Informatics* **ahead-of-print**, (2020).
73. Zhang, W. *et al.* Gait Symmetry Assessment with a Low Back 3D Accelerometer in Post-Stroke Patients. *Sensors* **18**, 3322 (2018).
74. Kourtis, L. C., Regele, O. B., Wright, J. M. & Jones, G. B. Digital biomarkers for Alzheimer's disease: the mobile/wearable devices opportunity. *npj Digital Medicine* **2**, 1–9 (2019).
75. Caramia, C. *et al.* IMU-Based Classification of Parkinson's Disease From Gait: A Sensitivity Analysis on Sensor Location and Feature Selection. *IEEE Journal of Biomedical and Health Informatics* **22**, 1765–1774 (2018).
76. Schmitz-Hübsch, T. *et al.* Accuracy and repeatability of two methods of gait analysis - GaitRite™ und Mobility Lab™ - in subjects with cerebellar ataxia. *Gait Posture* **48**, 194–201 (2016).
77. Caliandro, P. *et al.* Exploring Risk of Falls and Dynamic Unbalance in Cerebellar Ataxia by Inertial Sensor Assessment. *Sensors* **19**, 5571 (2019).
78. Krishna, R., Pathirana, P. N., Horne, M., Power, L. & Szmulewicz, D. J. Quantitative assessment of cerebellar ataxia, through automated limb functional tests. *Journal of NeuroEngineering and Rehabilitation* **16**, 31 (2019).
79. Mancini, M. *et al.* ISway: a sensitive, valid and reliable measure of postural control. *Journal of NeuroEngineering and Rehabilitation* **9**, 59 (2012).
80. Phan, D. *et al.* Quantitative Assessment of Ataxic Gait using Inertial Sensing at Different Walking Speeds. *Annu Int Conf IEEE Eng Med Biol Soc* **2019**, 4600–4603 (2019).
81. Procházka, A., Charvátová, H., Vyšata, O., Kopal, J. & Chambers, J. Breathing Analysis Using Thermal and Depth Imaging Camera Video Records. *Sensors (Basel)* **17**, (2017).
82. Procházka, A. *et al.* Extraction of breathing features using MS Kinect for sleep stage detection. *SIViP* **10**, 1279–1286 (2016).

83. Procházka, A., Schätz, M., Vyšata, O. & Vališ, M. Microsoft Kinect Visual and Depth Sensors for Breathing and Heart Rate Analysis. *Sensors (Basel)* **16**, (2016).
84. Boe, A. J. *et al.* Automating sleep stage classification using wireless, wearable sensors. *npj Digital Medicine* **2**, 1–9 (2019).
85. van Hees, V. T. *et al.* Estimating sleep parameters using an accelerometer without sleep diary. *Scientific Reports* **8**, 12975 (2018).
86. Celik, Y., Stuart, S., Woo, W. L. & Godfrey, A. Gait analysis in neurological populations: Progression in the use of wearables. *Medical Engineering & Physics* **87**, 9–29 (2021).
87. Suzuki, M., Mitoma, H. & Yoneyama, M. Quantitative Analysis of Motor Status in Parkinson’s Disease Using Wearable Devices: From Methodological Considerations to Problems in Clinical Applications. *Parkinson’s Disease* vol. 2017 e6139716 <https://www.hindawi.com/journals/pd/2017/6139716/> (2017).
88. Buckley, E., Mazzà, C. & McNeill, A. A systematic review of the gait characteristics associated with Cerebellar Ataxia. *Gait Posture* **60**, 154–163 (2018).
89. Phan, D. *et al.* Quantitative Assessment of Ataxic Gait using Inertial Sensing at Different Walking Speeds. *Conf Proc IEEE Eng Med Biol Soc* **2019**, 4600–4603 (2019).
90. McGinnis, R. S. *et al.* A machine learning approach for gait speed estimation using skin-mounted wearable sensors: From healthy controls to individuals with multiple sclerosis. *PLOS ONE* **12**, e0178366 (2017).
91. Diener, H. C., Dichgans, J., Bacher, M. & Guschlbauer, B. Characteristic alterations of long-loop ‘reflexes’ in patients with Friedreich’s disease and late atrophy of the cerebellar anterior lobe. *Journal of Neurology, Neurosurgery & Psychiatry* **47**, 679–685 (1984).
92. Frontiers | Long-latency reflexes account for limb biomechanics through several supraspinal pathways | Frontiers in Integrative Neuroscience. <https://www.frontiersin.org/articles/10.3389/fnint.2014.00099/full>.

93. Buckley, C. *et al.* The Role of Movement Analysis in Diagnosing and Monitoring Neurodegenerative Conditions: Insights from Gait and Postural Control. *Brain Sci* **9**, (2019).
94. López, A., Ferrero, F. & Postolache, O. An Affordable Method for Evaluation of Ataxic Disorders Based on Electrooculography. *Sensors* **19**, 3756 (2019).
95. Rizzo, G. *et al.* Accuracy of clinical diagnosis of Parkinson disease: A systematic review and meta-analysis. *Neurology* **86**, 566–576 (2016).