



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

POROVNÁNÍ DAT Z CHYTRÝCH TELEFONŮ, NÁRAMKŮ A SPECIALIZOVANÝCH ZAŘÍZENÍ

COMPARISON OF DATA FROM SMARTPHONES, FITNESS TRACKERS, AND SPECIALISED DEVICES

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Diana Kačníková

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Andrea Němcová

BRNO 2018

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**
Ústav biomedicínského inženýrství

Studentka: Diana Kačnicková

ID: 186663

Ročník: 3

Akademický rok: 2017/18

NÁZEV TÉMATU:

Porovnání dat z chytrých telefonů, náramků a specializovaných zařízení

POKYNY PRO VYPRACOVÁNÍ:

1) Prostudujte možnosti záznamu aktivity pomocí různých zařízení (např. chytrý telefon, fitness náramky, akcelerometr, krokoměr). 2) Nasnímejte testovací signál pomocí několika zařízení (např. chytrý telefon, Axivity). 3) Navrhněte algoritmy pro hodnocení aktivity (např. index aktivity, detekce pádu, krokoměr). 4) Nasnímejte signály pomocí různých zařízení zároveň. Testujte různé podmínky snímání (např. vliv umístění chytrého telefonu, typ telefonu, vzorkovací frekvence). 5) Aplikujte navržené algoritmy na nasnímané signály. 6) Porovnejte testovaná zařízení a místa snímání a diskutujte jejich použitelnost.

DOPORUČENÁ LITERATURA:


[1] BASSETT, David R., Lindsay P. TOTH, Samuel R. LAMUNION a Scott E. CROUTER. Step Counting: A Review of Measurement Considerations and Health-Related Applications. Sports Medicine. 2017, 47(7), 1303-1315. ISSN 0112-1642.

[2] FENG, Yuanyuan, Christopher K. WONG, Vandana JANEJA, Ravi KUBER a Helena M. MENTIS. Comparison of tri-axial accelerometers step-count accuracy in slow walking conditions. Gait. 2017, 53, 11-16. ISSN 09666362.

Termín zadání: 5. 2. 2018

Termín odevzdání: 25. 5. 2018

Vedoucí práce: Ing. Andrea Němcová


prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č.121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Abstrakt

Táto bakalárska práca sa zaoberá porovnávaním dát z chytrých telefónov, náramkov a špecializovaných zariadení. V práci je zahrnutý popis možností záznamu pomocou rôznych zariadení ako je chytrý telefón, náramok Axivity AX3 a Fitbit Alta HR. Pomocou týchto zariadení boli nasnímané signály s rôznymi umiestneniami a vzorkovacími frekvenciami. Takto nasnímané signály sa implementovali na tri vytvorené algoritmy pre klasifikáciu aktivít. Pre každý signál sa vypočítala presnosť detekcie a na základe týchto presností sa porovnali zariadenia, umiestnenia zariadení a vzorkovacie frekvencie. Stanovila sa ideálna kombinácia vzorkovacej frekvencie, umiestnenia a typu snímacieho zariadenia.

Kľúčové slova

Akcelerometer, Axivity AX3, chytrý telefón, detekcia pádu, FitBit Alta HR, fyzická aktivita, krokomer

Abstract

The focus of this thesis is the comparison of data from smart phones, fitness bracelets and specialized devices. Thesis includes description of features when using special devices such as smart phone, Axivity AX3 bracelet and Fitbit Alta HR for data recording. Signals were recorded using those devices with different anatomical locations and sampling frequencies. Those data recorded were implemented for three algorithms created for activity classification. Detection accuracy was calculated for each signal recorded. Devices, sampling frequencies and anatomical locations were compared based on the accuracy. Ultimate combination of sampling frequency, anatomical location and suitable device was defined.

Keywords

Accelerometer, Axivity AX3, smartphone, fall detection, Fitbit Alta HR, physical activity, step counter

Bibliografická citace:

KAČNÍKOVÁ, D. *Porovnání dat z chytrých telefonů, náramků a specializovaných zařízení*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2018. 74 s. Vedoucí bakalářské práce Ing. Andrea Němcová.

Prohlášení

„Prohlašuji, že svou závěrečnou práci na téma „Porovnání dat z chytrých telefonů, náramků a specializovaných zařízení“ jsem vypracovala samostatně pod vedením vedoucej bakalárskej práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autorka uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědoma následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brne dňa 25.5.2018

.....
podpis autorky

Pod'akovanie

Ďakujem vedúcej bakalárskej práce Ing. Andrei Němcovéj za účinnú metodickú, pedagogickú a odbornú pomoc a ďalšie cenné rady pri spracovaní mojej bakalárskej práce.

V Brne dňa 25.5.2018

.....
podpis autorky

Obsah

Úvod.....	12
1 Možnosti záznamu aktivity pomocou rôznych zariadení	13
1.1 Chytrý telefón	13
1.2 Fitness náramok Fitbit Alta HR	14
1.3 Axivity AX3	15
2 Hodnotené aktivity a aplikácie	16
2.1 Možnosti hodnotenia aktivity človeka	16
2.2 Aplikácie	18
Lifelog [19][20]	18
Step counter [21]	18
Sense-it [22]	18
Lab4Physics [23]	19
Sparkvue [24]	19
Accelerometer Analyzer [25]	19
3 Snímanie dát	21
3.1 Testovanie Fitbit Alta HR	21
3.2 Signál pre hodnotenie vytvorených algoritmov	22
3.3 Signály pre porovnanie zariadení	24
4 Algoritmus pre hodnotenie aktivity	29
4.1 Rozšírený algoritmus detekcie pádu	29
4.2 Krokomer	34
4.2.1 Krokomer 1	34
4.2.2 Krokomer 2	37
5 Presnosť navrhnutých algoritmov	42
5.1 Presnosť rozšíreného algoritmu detekcie pádu	42
5.2 Presnosť krokomerov	44
5.2.1 Presnosť krokomeru 1	44
5.2.2 Presnosť krokomeru 2	46
6 Porovnanie presnosti rozpoznania aktivít a detekcia krokov pomocou chytrého telefónu a náramku Axivity AX3	47
6.1 Rozšírený algoritmus detekcie pádu	47
6.1.1 Sense it x Axivity AX3	47
6.1.2 Accelerometer analyzer x Axivity AX3	49
6.2 Krokomer 1	50
6.2.1 Sense it x Axivity AX3	50
6.2.2 Accelerometer analyzer x Axivity AX3	52
6.3 Krokomer 2	53
6.3.1 Sense it x Axivity AX3	53

6.3.2	Accelerometer analyzer x Axivity AX3	55
7	Vyhodnotenie úspešnosti detekcie	56
7.1	Úspešnosť detekcie v závislosti na vzorkovacej frekvencii a mieste snímania.....	56
7.2	Presnosť jednotlivých algoritmov	59
7.3	Štatistické zhodnotenie kvality použitých zariadení	60
7.4	Presnosť jednotlivých aktivít v algoritmoch.....	62
8	Diskusia	66
	Záver	68
	Literatura	69
	Zoznam symbolov, veličín a skratiek	74
	Zoznam príloh	74
8.1	Obsah priloženého CD.....	74

Zoznam obrázkov

Obrázok 1.1 Umiestnenie chytrého telefónu pri snímaní balistokardiogramu, prevzaté z [4].....	14
Obrázok 1.2 Možnosť nastavenia záznamu v aplikácii OmGui.....	15
Obrázok 3.1 Signál (SVM) pre hodnotenie aktivity prostredníctvom modifikovaného algoritmu detekcie pádu	23
Obrázok 3.2 Priblíženie aktivity pádu	23
Obrázok 3.3 Signál (SVM) pre hodnotenie prostredníctvom krokomeru	24
Obrázok 3.4 Signál (SVM) pre hodnotenie prostredníctvom krokomeru	24
Obrázok 3.5 SVM testovacieho signálu 1 (Axivity AX3, členok, 50 Hz).....	25
Obrázok 3.6 SVM testovacieho signálu 1 (aplikácia Sense it, lýtkový sval, 50 Hz)..	26
Obrázok 3.7 SVM testovacieho signálu 24 (Axivity AX3, členok, 100 Hz)	26
Obrázok 3.8 SVM testovacieho signálu 24 (Accelerometer Analyzer, lýtkový sval, 100 Hz)	27
Obrázok 3.9 SVM testovacieho signálu 46 (Axivity AX3, biceps, 25 Hz)	28
Obrázok 3.10 SVM testovacieho signálu 46 (aplikácia Sense it, biceps, 25 Hz)	28
Obrázok 4.1 Bloková schéma modifikovanej verzie detekcie pádu.....	29
Obrázok 4.2: Porovnanie SVM s použitím a bez použitia mediánovej filtrácie	30
Obrázok 4.3 Porovnanie SMA pri rôznych veľkostiach okna $w = 25$ vzoriek, $w = 75$ vzoriek a $w = 125$ vzoriek.....	31
Obrázok 4.4 Tilt angle	32
Obrázok 4.5 Vzory aktivity pre stanovenie hraničného priemeru	33
Obrázok 4.6 Bloková schéma pre algoritmus krokomeru	34
Obrázok 4.7 Raw dáta zo špecializovaného zariadenia (X, Y, Z os).....	35
Obrázok 4.8 Výsledok výpočtu SVM s nulovou izolíniou	35
Obrázok 4.9 Detekcia krokov bez úpravy a s úpravou minimálnej vzdialenosti.....	36
Obrázok 4.10 Detail detekcie krokov bez úpravy a s úpravou minimálnej vzdialenosti	36
Obrázok 4.11 Bloková schéma algoritmu krokomeru 2.....	37
Obrázok 4.12 Bloková schéma pre výpočet prahov pre dané aktivity	39
Obrázok 4.13 Odhad kvadrátu obálky a umocnenie odhadu kvadrátu obálky	39
Obrázok 4.14 Rozklad signálu prostredníctvom EMD na IMF 1,4 a rezíduum.....	40
Obrázok 4.15 Prahovanie signálu.....	41
Obrázok 4.16 Priblíženie prahovania	41
Obrázok 5.1 Výsledok detekcie prostredníctvom modifikovaného algoritmu detekcie pádu	43
Obrázok 5.2 Detail nepresnosti detekcie	43
Obrázok 5.3 Detail detekcie pádu.....	43

Obrázok 5.4 Výsledok detekcie prostredníctvom algoritmu krokomeru 1 (2 kroky za 1,7 s)	45
Obrázok 5.5 Výsledok detekcie prostredníctvom algoritmu krokomeru 1 (2 kroky za 2s)	45
Obrázok 5.6 Výsledok hodnotenia aktivity prostredníctvom krokomeru 2	46
Obrázok 7.1 Graf závislosti presnosti zariadení na f_{vz} a umiestnenia zariadení	58
Obrázok 7.2 Graf závislosti presnosti zariadení na voľbe algoritmov	59
Obrázok 7.3 Rozloženie hodnôt pre chytrý telefón	61
Obrázok 7.4 Rozloženie hodnôt pre Axivity AX3	61
Obrázok 7.5 Graf závislosti presnosti zariadení na konkrétnych aktivitách (algoritmus 1)	63
Obrázok 7.6 Graf závislosti presnosti zariadení na konkrétnych aktivitách (algoritmus 2)	64
Obrázok 7.7 Graf závislosti presnosti zariadení na konkrétnych aktivitách (algoritmus 3)	65

Zoznam tabuliek

Tabuľka 3.1 Priradenie farieb pre aktivity	22
Tabuľka 4.1 Priemer a variačný koeficient pre dané aktivity.....	33
Tabuľka 4.2 Maximá pre aktivity nasnímané Axivity AX3 a chytrým telefónom.....	38
Tabuľka 5.1 Odhad chýb pre konkrétny typ aktivity a presnosť detekcie (algoritmus detekcie pádu)	42
Tabuľka 5.2 Odhad chýb pre konkrétny typ aktivity a presnosť detekcie (krokomer 1)	44
Tabuľka 5.3 Odhad chýb pre konkrétny typ aktivity a presnosť detekcie (krokomer 2)	46
Tabuľka 6.1 Presnosť pre rozšírený algoritmus detekcie pádu (50 Hz, noha a Sense it)	47
Tabuľka 6.2 Presnosť pre rozšírený algoritmus detekcie pádu (100 Hz, noha a Sense it)	48
Tabuľka 6.3 Presnosť pre rozšírený algoritmus detekcie pádu (25 Hz, noha a Sense it)	48
Tabuľka 6.4 Presnosť pre rozšírený algoritmus detekcie pádu (50 Hz, biceps a Sense it)	48
Tabuľka 6.5 Presnosť pre rozšírený algoritmus detekcie pádu (100 Hz, biceps a Sense it)	48
Tabuľka 6.6 Presnosť pre rozšírený algoritmus detekcie pádu (25 Hz, biceps a Sense it)	48
Tabuľka 6.7 Presnosť pre rozšírený algoritmus detekcie pádu (50 Hz, noha a Accelerometer Analyzer)	49
Tabuľka 6.8 Presnosť pre rozšírený algoritmus detekcie pádu (100 Hz, noha a Accelerometer Analyzer)	49
Tabuľka 6.9 Presnosť pre rozšírený algoritmus detekcie pádu (50 Hz, biceps a Accelerometer Analyzer)	49
Tabuľka 6.10 Presnosť pre rozšírený algoritmus detekcie pádu (100 Hz, biceps a Accelerometer Analyzer)	49
Tabuľka 6.11 Presnosť pre krokomer 1 (50 Hz, noha a Sense it).....	50
Tabuľka 6.12 Presnosť pre krokomer 1 (100 Hz, noha a Sense it).....	50
Tabuľka 6.13 Presnosť pre krokomer 1 (25 Hz, noha a Sense it).....	51
Tabuľka 6.14 Presnosť pre krokomer 1 (50 Hz, biceps a Sense it).....	51
Tabuľka 6.15 Presnosť pre krokomer 1 (100 Hz, biceps a Sense it).....	51
Tabuľka 6.16 Presnosť pre krokomer 1 (25 Hz, biceps a Sense it).....	51
Tabuľka 6.17 Presnosť pre krokomer 1 (50 Hz, noha, Accelerometer Analyzer) ...	52
Tabuľka 6.18 Presnosť pre krokomer 1 (100 Hz, noha a Accelerometer Analyzer)	52

Tabuľka 6.19 Presnosť pre krokomer 1 (50 Hz, biceps, Accelerometer Analyzer)	52
Tabuľka 6.20 Presnosť pre krokomer 1 (100 Hz, biceps a Accelerometer Analyzer)	52
Tabuľka 6.21 Presnosť pre krokomer 2 (50 Hz, noha a Sense it)	53
Tabuľka 6.22 Presnosť pre krokomer 2 (100 Hz, noha a Sense it)	53
Tabuľka 6.23 Presnosť pre krokomer 2 (25 Hz, noha a Sense it)	53
Tabuľka 6.24 Presnosť pre krokomer 2 (50 Hz, biceps a Sense it)	54
Tabuľka 6.25 Presnosť pre krokomer 2 (100 Hz, biceps a Sense it)	54
Tabuľka 6.26 Presnosť pre krokomer 2 (25 Hz, biceps a Sense it)	54
Tabuľka 6.27 Presnosť pre krokomer 2 (50 Hz, noha, Accelerometer Analyzer) ...	55
Tabuľka 6.28 Presnosť pre krokomer 2 (100 Hz, noha, Accelerometer Analyzer)	55
Tabuľka 6.29 Presnosť pre krokomer 2 (50 Hz, biceps, Accelerometer Analyzer)	55
Tabuľka 6.30 Presnosť pre krokomer 2 (100 Hz, biceps, Accelerometer Analyzer)	55
Tabuľka 7.1 Presnosť pre jednotlivé tabuľky	57
Tabuľka 7.2 Presnosť detekcie pre zariadenia v závislosti na umiestnení a vzorkovacej frekvencií	57
Tabuľka 7.3 Úspešnosť detekcie pre algoritmy	59
Tabuľka 7.4 Úspešnosť detekcie pre jednotlivé záznamy	60
Tabuľka 7.5 Wilcoxonov párový test	62
Tabuľka 7.6 Výsledok korelácie	62
Tabuľka 7.7 Úspešnosť detekcie aktivít pre algoritmus 1	63
Tabuľka 7.8 Úspešnosť detekcie aktivít pre algoritmus 2	64
Tabuľka 7.9 Úspešnosť detekcie aktivít pre algoritmus 3	64

ÚVOD

Táto práca sa zaoberá problematikou snímania a hodnotenia ľudskej aktivity. Rozpoznanie ľudskej činnosti z nositeľných zariadení je sľubné pre zdravotnú starostlivosť, vyhodnotenie športových výkonov a ohodnotenie životného štýlu.

Zaznamenávanie signálov je prostredníctvom senzorov, predovšetkým akcelerometru. V dnešnej dobe každý chytrý telefón a tablet obsahuje integrovaný akcelerometer. Podľa posledných dostupných informácií ČSÚ pripadá na sto domácností 206 chytrých telefónov [1] a vo veku viac ako 15 rokov vlastní telefón 74 % populácie, pričom vo veku 25-34 rokov táto hodnota stúpa až na 94 % [2]. Preto je snaha využiť ich rozšírenie a schopnosti.

Najväčšou motiváciou je detekcia pádu. Pád patrí medzi hlavné príčiny zranení a so systémom, ktorý by dokázal detekovať pád, následnú neaktivitu osoby a po vyhodnotení týchto informácií kontaktovať zdravotné strediská by sa znížila doba čakania na zdravotnícku pomoc. Znížením doby čakania sa zároveň znižujú následky úrazu pre pacienta.

Cieľom tejto práce bude popísať možnosti záznamu aktivity pomocou rôznych zariadení a nasnímať viacero signálov prostredníctvom popísaných zariadení. Nasnímané signály budú hodnotené tromi vytvorenými algoritmami. V prvom algoritme bude detekovaný pád a aktivity ako je beh, ľah, sed a chôdza. V druhom a treťom algoritme bude detekovaný počet krokov a aktivity: beh, ľah a státie. Výsledok detekcie sa porovná s referenciami, takto určené presnosti sa štatisticky vyhodnotia. Určí sa optimálna vzorkovacia frekvencia, umiestnenie a výber zariadenia.

1 MOŽNOSTI ZÁZNAMU AKTIVITY POMOCOU RÔZNYCH ZARIADENÍ

Snímanie ľudskej aktivity je možné viacerými zariadeniami, či už špecializovanými alebo bežne používanými. Medzi zariadenia, ktoré sú schopné snímať ľudskú aktivitu zaraďujeme chytré telefóny, tablety, fitness náramky, chytré hodinky, akcelerometre.

Fitness náramky a chytré hodinky sú dva z mnohých typov nositeľných inteligentných zariadení. Fitness náramok je zariadenie, vďaka ktorému sa monitoruje každodenná pohybová aktivita. Po pripojení s telefónom resp. aplikáciou neumožňujú telefonovať ani písať správy. Zatiaľ čo chytré hodinky po prepojení s telefónom umožňujú prijímanie hovorov, zasielanie správ, upozornenie na správy zo sociálnych sietí a aplikácií, budík, kalendár, prehrávanie videí a mnoho ďalších. Drahšie modely ponúkajú senzor srdcového tepu, krokomer, meranie kalórií a analýzu spánku.

Zariadenia ako sú chytré telefóny, chytré hodinky, tablety obsahujú integrované senzory ako sú akcelerometer, barometer, gyroskop, senzor intenzity magnetického poľa. Primárne využitie akcelerometru je meranie orientácie telefónu, čo je využité napríklad v hrách. Gyroskop podobne ako akcelerometer meria natočenie a naklonenie zariadenia.

Pri zariadeniach ako sú fitness náramky je veľmi častá problematika získania dát. Presnejšie a jednoduchšie získanie informácií umožňujú zariadenia, ktoré obsahujú akcelerometer a ten je primárne určený pre snímanie ľudskej aktivity (Axivity AX3).


1.1 Chytrý telefón

Pre získanie dát sa vo väčšine prípadov môžu použiť aplikácie pre chytrý telefón s využitím akcelerometru, gyroskopu, senzoru intenzity magnetického poľa, poprípade ďalších senzorov. Existuje široká škála prístupných aplikácií.

Väčšina aplikácií využíva senzor akcelerometru, a preto sa táto práca zaoberá týmto sensorom. Aplikácie využívajúce akcelerometer sa rozlišujú v možnosti zmeny vzorkovacej frekvencie a v možnosti odčítania gravitačného zrýchlenia. Väčšina aplikácií meria zrýchlenie v jednotkách ms^{-2} , menej časté je meranie v jednotkách g. Medzi hlavné faktory pri výbere aplikácie sa pokladá spôsob exportu dát, nutnosť internetového pripojenia a získanie surových dát. Za hlavnú nevýhodu sa môže pokladať prerušenie merania pri zamknutí chytrého telefónu. V prípade snímania chytrým telefónom často dochádza ku nasnímaniu artefaktov, vznik týchto artefaktov je spôsobený vibráciami telefónu pri prichádzajúcich telefonátoch a správ. Tieto artefakty sú však krátke a malé preto neovplyvňujú detekciu aktivít.

Podľa typu získaných dát sa aplikácie rozdeľujú do dvoch skupín a to aplikácie poskytujúce surové dáta a aplikácie poskytujúce spracované dáta. Do druhej skupiny sa zaraďujú tzv. sledovače aktivity, ktorých výstupom je konkrétny počet krokov, vzdialenosť, kalórie [3]. Popis konkrétnych aplikácií nájdeme v kapitole 2. Okrem sledovačov aktivity sa tu zaraďujú aplikácie pre stanovenie tepovej frekvencie (TF), tlaku alebo saturácie.

Pre stanovenie TF je možnosť použiť metódu balistokardiografiu. Ide o neinvazívnu metódu, ktorá na základe srdečnej aktivity zaznamenáva zmeny pohybu tela. Výstupom balistokardiografie je balistokardiogram. Medical Tricorder je aplikácia, ktorá sníma údaje z chytrého telefónu prostredníctvom senzoru - akcelerometra. Zachytávajú, filtrujú a analyzujú sa pohybové signály generované počas srdcových cyklov na povrchu hrudníka. Umiestnenie chytrého telefónu je zobrazené na obrázku číslo 1.1 [4].



Obrázok 1.1 Umiestnenie chytrého telefónu pri snímaní balistokardiogramu, prevzaté z [4]

Druhá metóda stanovenia TF využíva zabudovaný mikrofón chytrého telefónu. V tomto prípade sa zaznamenávajú zvuky vygenerované srdcom a krvným prúdením. Hodnotia sa hlavne dva výrazné zvuky srdca. Umiestnenie telefónu je na hrudi osoby, ktorá leží. [5]

Stanovenie saturácie krvi kyslíkom sa vykonáva prostredníctvom kamery chytrého telefónu. Chytrý telefón využíva LED ako svetelný zdroj a fotoaparát ako detektor. [6]

1.2 Fitness náramok Fitbit Alta HR

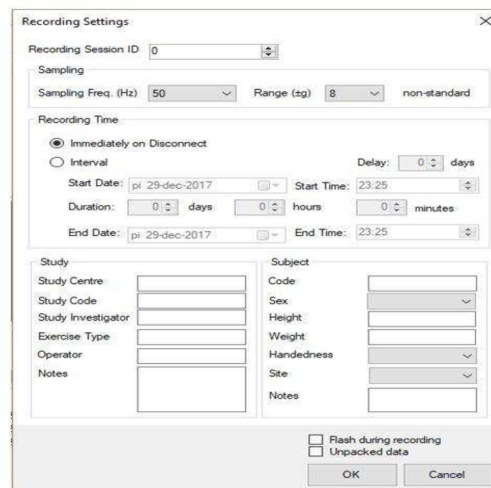
Fitbit Alta HR je zariadenie, ktoré monitoruje osobné celodňové aktivity. Podobne ako väčšina fitness náramkov neposkytuje surové dáta. Informácie snímajú pomocou integrovaného akcelerometru a následne ich spracúvajú bez uloženia, dôvodom je šetrenie pamäti. Toto zariadenie na oplátku poskytuje informácie o počte krokov, celkovej prejdenej vzdialenosti, počte spálených kalórií a tepovej frekvencii. Okrem informácií o aktivitách uskutočňovaných počas dňa sníma aj spánok konkrétne rozlišuje bdelosť, plytký, hlboký spánok a REM fázu (fáza spánku s rýchlymi pohybmi očí) [7].

Pre získanie informácií je potreba toto zariadenie spárovať s mobilným zariadením alebo počítačom prostredníctvom aplikácie Fitbit s využitím bluetooth. Táto aplikácia je dostupná pre zariadenia s iOS, Android aj Windows phone. Avšak spárovať zariadenie s aplikáciou nefunguje pre všetky mobilné zariadenia (musí byť podporovaný typ telefónu - cca 120 typov podporovaných).

1.3 Axivity AX3

Axivity AX3 je komerčne dostupný tri-osový akcelerometer typu MEMS (microelectromechanical systems) [8]. Jeho hmotnosť je 11 g a rozmery (23 × 32,5 × 7,6) mm. Vďaka rozmerom, hmotnosti a možnosti dokúpenia hodinkového náramku, kde sa zariadenie umiestni je toto zariadenie jednoducho nositeľné a teda neovplyvňuje výsledky merania. Axivity AX3 poskytuje možnosť nastavenia vzorkovacej frekvencie a to v rozmedzí (6,25 – 3 200) Hz. Obrovskou výhodou je pamäť, ktorá disponuje až 512 Mb. Výdrž batérie je závislá na vzorkovacej frekvencii, pri použití 12,5 Hz je výdrž batérie 30 dní, pri vzorkovacej frekvencii 100 Hz len 14 dní. [9]

Pripojenie s počítačom je prostredníctvom Micro USB. Pre prácu s Axivity AX3 je potrebná aplikácia pre Windows a to OmGui. V tejto aplikácii dochádza ku nastavovaniu snímača pre meranie. Meranie môže byť spustené hneď po odpojení snímacieho zariadenia od počítača alebo v presne definovaný okamih [9]. Obrázok 1.2 nám zobrazuje možnosti nastavenia záznamu.



Obrázok 1.2 Možnosť nastavenia záznamu v aplikácii OmGui

OmGui obsahuje nástroje na analýzu konkrétne výpočet SVM (Signal magnitude vector - popísané v kapitole 4) (1) a cut-point analýzu. Cut-point analýza udáva čas, ktorý osoba strávila fyzickou aktivitou o špecifickej intenzite. [9]

Axivity AX3 bolo testované a výsledky testovania publikované v článku [8], toto testovanie sa vykonávalo na 25 zdravých účastníkov. Porovnávali sa kroky namerané a spočítané (video záznam). Toto meranie sa vykonávalo na trenažéry pre konštantnú rýchlosť. A to pre rýchlosti 0,9 m/s, 1,1 m/s a 1,3 m/s. Určujeme chyby- podhodnotenie a nadhodnotenie krokov. Axivity AX3 malo najmenšie percento chýb v porovnaní s ďalšími dvoma zariadeniami (Actigraph wGT3X-BT, APDM Opal). Za nadhodnotenie krokov pokladáme keď v skutočnosti krok nebol vykonaný, ale zariadenie krok započíta. Naopak podhodnotenie keď je krok vykonaný, ale nezapočítaný. Chyba pre nadhodnotenie krokov je 22,2 % a pre podhodnotenie krokov 37,7%, zatiaľ čo Actigraph wGT3X-BT vykazoval chyby až 50 %. Na základe tohoto testovania sa určilo Axivity AX3 z týchto 3 zariadení ako najpresnejšie. [8]

2 HODNOTENÉ AKTIVITY A APLIKÁCIE

Monitorovanie ľudskej fyzickej aktivity nám poskytuje potrebné informácie týkajúce sa všeobecnej úrovne činnosti človeka. Monitorovanie v reálnom čase môže byť veľmi prospešné pre osoby so zdravotnými problémami. Ako hlavnú skupinu ľudí, pre ktorých je hodnotenie prospešné sa pokladajú starší ľudia, kde je najvyššie riziko pádu, ktorý spôsobí vážne zdravotné zranenie [10]. Hodnotenie aktivity a hlavne pádu je veľmi užitočné hlavne pre ľudí, ktorí bývajú sami a v prípade pádu a zranenia nemajú osobu, ktorá by zabezpečila zdravotnú pomoc. V tomto prípade by zariadenie zaznamenalo pád a pokiaľ by osoba neodsúhlasila, že je v poriadku, zaslalo by sa upozornenie pre kompetentné osoby. V rámci tejto informácie je vhodné zaslať aj GPS polohu osoby.

V dnešnej dobe sa väčšina ľudí zaujíma o to akým spôsobom trávi svoj čas. A tak využívajú monitorovanie ľudskej aktivity pre získanie časových informácií o vykonávaní konkrétnych aktivít v priebehu dňa. Najčastejšie sa hodnotia aktivity ako je beh, chôdza, kráčanie po schodoch, sedenie, ľah (spánok), státie, pád, cestovanie dopravným prostriedkom [10], [11]. Pre hodnotenie každej aktivity je ideálne umiestnenie snímacieho zariadenia rozdielne. Pre chôdzu a beh je odporúčané umiestnenie na členku zatiaľ čo pri prioritnom snímaní pádu sa pokladá za ideálne umiestnenie na páse. Preto pri snímaní všetkých aktivít je potrebný kompromis v umiestnení zariadenia.

Pre hodnotenie aktivity existuje mnoho algoritmov. Väčšina z nich obsahuje predspracovanie signálu a samotnú detekciu aktivít. Priebeh algoritmov sa väčšinou člení ako „strom“. Prvým rozhodovacím pravidlom je či zariadenie sníma pohyb. Ak sa zariadenie nesníma pohyb systém pokračuje v odhadovaní akú aktivitu vykonáva (sedenie, státie, jazda autom, ...). V rámci tohto odhadovania dochádza ku určovaniu polohy tela. Niektoré algoritmy určujú orientáciu ľahu [11]. Pokiaľ sa osoba pohybuje dochádza ku odhadu či ide o chôdzu, beh, cyklistiku, ... [12]

2.1 Možnosti hodnotenia aktivity človeka

Staršie snímacie zariadenia obsahovali len jednoosové akcelerometre. Nástup MEMS (mikroelektromechanické systémy) technológie umožnil miniaturizáciu dovtedy väčších a ťažších senzorov. Vznikli malé, ľahké a lacné trojosové akcelerometre, gyroskopy, magnetometre, poprípade barometre, ktoré sa stali súčasťou chytrých telefónov [13]. Nositeľné senzory podobne ako aj chytré telefóny majú obrovskú perspektívu v monitorovaní ľudskej aktivity. Proces klasifikácie pohybu je zložený z troch fáz: snímanie, extrakcia informácií a klasifikácia aktivít.

Snímanie prostredníctvom viacerých senzorov s rôznym umiestnením môže viesť ku lepším výsledkom, kedy použitie jedného senzoru nemusí byť dostatočné napr. pri umiestnení snímacieho zariadenia na biceps nie sme schopný rozlíšiť státie od sedenia [14]. Dlhodobé snímanie vyžaduje dlhú výdrž batérie snímacieho zariadenia a to je jeden z dôvodov minimalizácie počtu zariadení [13]. Najčastejšie typy senzorov, ktoré sú používané súčasne sú akcelerometer a gyroskop. Gyroskop nemeria ako akcelerometer

zrýchlenie, ale meria uhlovú rýchlosť, preto ich vzájomné použitie určí presnejšie naklonenie a natočenie snímacieho zariadenia. Ďalším sensorom, ktorý by za istých podmienok spresnil snímanie aktivít je barometer, barometer však obsahuje málo snímacích zariadení (len najnovšie typy telefónov) a preto je táto kombinácia menej častá aj napriek lepšej presnosti (výhodné použiť pre detekciu chôdze po schodoch). Pre presnejšiu klasifikáciu aktivít sa využíva mikrofón (napr. pri snahe rozpoznať aktivít vykonávaných rukami – umývanie riadu, práca na počítači, ...). Pri využití mikrofónu sa vychádza z predpokladu, že všetky činnosti, ktoré chceme detekovať vytvárajú istý typ hluku v blízkosti ruky) [15]. V robustnejšej analýze sa stretávame aj s rozoznávaním dopravných prostriedkov, kedy je potrebné využiť GPS sensor [16].

Extrakcia informácií zahŕňa spracovanie signálu (mediánová filtrácia, odstránenie gravitačného pôsobenia, ...) [17] a metódy extrakcie prvkov, ktoré sú dôležité pre zredukovanie surových dát zo sensorov na konečný počet odvodených parametrov. Tieto parametre ovplyvňujú fyzický pohyb. Extrakcia je prevedená prostredníctvom posuvného okna charakterizujúceho niekoľko sekúnd záznamu a s 50 % prekrývaním medzi jednotlivými posunmi [13].

Posledným krokom je klasifikácia aktivít pomocou rôznych algoritmov a klasifikačných modelov. Tieto modely sú natréňované prostredníctvom MLA (machine learning algorithm), ktoré analyzujú údaje o tréningoch počas procesu učenia a definujú pravidlá, ktoré sa neskôr využívajú na rozdelenie tréningových dát do skupín. Skupiny definujú typ aktivity. Príklady MLA, ktoré môžu byť využité na vytvorenie modelu pre rozlíšenie ľudskej aktivity: KNN (K Nearest Neighbours), DTC (Decision Tree Classifiers), HMM (Hidden Markov Models) ...

Príkladom robustnej analýzy je článok [18], ktorý je schopný rozoznať nielen aktivity, ale aj prepravu osoby pomocou dopravného prostriedku. Vstupom do tohto algoritmu sú dáta z akcelerometru, mikrofónu a GPS. Dáta z akcelerometru rozhodnú či osoba vykonáva aktivitu ako je beh, chôdza, chôdza do schodov, chôdza zo schodov, bicyklovanie, státie, sedenie alebo cestuje dopravným prostriedkom. Dáta z GPS overia túto klasifikáciu a dáta z mikrofónu zachytia zvukové údaje, ktoré sa využijú na rozoznanie typu dopravného prostriedku. Algoritmus využíva tieto senzory pre rozoznanie viacerých aktivít, a zvýšenie presnosti detekcie aktivít. Pre lepšiu časovú vydrž zariadenia nesnímajú všetky senzory neustále, dochádza ku ich aktivácii v prípade potreby napr. systém rozpozna dopravu (vďaka tomu, že odvodí trasu GPS), aktivuje sa mikrofón, keď systém zaznamená chôdzu, mikrofón je zastaví zhromažďovanie dát [16], [18]. Motiváciou bolo vytvoriť robustný algoritmus, ktorý využíva senzory ponúkané chytrým telefónom. Algoritmus bol testovaný na Androide a presnosť rozoznania aktivít v tomto algoritme dosiahla 92,43 % čo sa pokladá za úspešnú detekciu v prípade snímania veľkého množstva aktivít [18].

2.2 Aplikácie

Lifelog [19][20]

Lifelog 4.0.A.0.14 je aplikácia pre Android 4.4 a vyšší. Táto aplikácia zaznamenáva aktivity ako beh, chôdzu, bicyklovanie, jazdu autom, dobu spánku a na základe informáciách o týchto aktivitách vypočítava hodnotu spálených kalórií. Aplikácia bola vybraná hlavne preto, že zbiera informácie nielen zo senzorov telefónu, ale aj konkrétne z ostatných aplikácií a vďaka tomu je schopná hodnotiť, koľko času človek strávi počúvaním hudby, pozeraním videí, prehľadávaním webu, hraním hier dokonca aj fotografovaním. V tejto aplikácii je možné pri každej aktivite nastaviť svoj cieľ a sledovať splnenie tohto cieľa. Pre presnejšie sledovanie aktivity sa dá spárovať s náramkom SmartBand od firmy Sony.

Step counter [21]

Step Counter- Pedometer Free & Calorie Counter 1.0.19A je aplikácia pre Android 4.1 a vyššie. Táto aplikácia bola vybraná z dôvodu najlepšieho hodnotenia užívateľmi. Aplikácia sa venuje iba počítaniu krokov, výpočtu kalórií a prejdenej vzdialenosti. Po nainštalovaní aplikácie je potrebné nastaviť pohlavie, hmotnosť a výšku. Váhu a výšku používa pre výpočet kalórií, zatiaľ čo výšku na výpočet dĺžky kroku. Výška sa vynásobí koeficientom 0,4 a dostaneme dĺžku kroku. Aplikácia dokonca dovoľuje manuálne nastavenie dĺžky kroku. Odporúčané miesto nosenia zariadenia je v ruke a vo vrecku. Počas cestovania autom alebo iným dopravným prostriedkom dochádza ku nesprávnemu počítaniu krokov a preto vývojári odporúčajú pozastavenie aplikácie a po docestovaní následné obnovenie. Ako jedna z mála aplikácií dovoľuje nastavenie až štyri úrovne citlivosti. Avšak vývojári upozorňujú, že pri veľkej citlivosti môže dochádzať ku počítaniu krokov aj pri malých pohyboch telefónom.

Sense-it [22]

Sense-it 1.2 Beta 20 je aplikácia pre Android 2.2 a vyšší. Aplikácia nevyhodnocuje aktivity, ale umožňuje získanie dát zo senzorov ako je akcelerometer, gravitačný senzor, gyroskop, senzor polohy, senzor intenzity svetla, zvuku poprípade magnetického poľa a mnoho ďalších. V našom prípade bol používaný akcelerometer. Tento akcelerometer meria zrýchlenie [ms^{-2}] v troch osách x, y a z (vrátane gravitačného zrýchlenia). Výsledné dáta sú uložené vo formáte *.CSV. Po spustení merania môžeme snímaný signál sledovať, následne ho uložiť, premenovať a zdieľať prostredníctvom emailu, Bluetoothu, WhatsApp-u. Za výhody sa pokladá maximálna vzorkovacia frekvencia až 100 Hz a fakt, že aplikácia nevyžaduje internetové pripojenie. Aplikácia je schopná merať aj na pozadí avšak pri uzamknutí telefónu sa meranie preruší. Aplikácia Sense it je jedna z dvoch testovaných aplikácií v tejto práci.

Lab4Physics [23]

Lab4Physics 2.5.4.8 je aplikácia pre Android (4.0.3 a vyšší), iOS a Windows. Táto aplikácia využíva mobilné senzory ako sú mikrofón, akcelerometer a fotoaparát. Nástroj pre využitie senzoru akcelerometru je dostupný zadarmo. Pre využitie telefónneho zariadenia ako sonometru je potrebné zakúpiť plnú verziu. Aplikácia meria zrýchlenie v $[ms^{-2}]$ rovnako ako aj aplikácia Sense-it v troch osách x,y a z (vrátane gravitačného zrýchlenia). Ako nevýhoda tejto aplikácie sa pokladá nemožnosť nastavenia vzorkovacej frekvencie. Táto frekvencia nie je nikde uvedená avšak pri nasnímaní niekoľkých signálov sme na základe počtu vzoriek schopný určiť jej približnú hodnotu. Táto hodnota kolíše v rozmedzí 40–50 Hz. Nasnímaný signál sa ukladá do formátu *.CSV. Všetky nasnímané signály je možné uložiť do aplikácie, pomenovať a späťne sa k ním vrátiť premenovať a dodatočne exportovať. Aplikácia nie je schopná merať na pozadí a teda ani po uzamknutí telefónu. Aplikácia umožňuje pozorovať priebeh snímaného signálu v reálnom čase avšak pri dlhšom meraní (viac ako 1 minúta) to spôsobuje problémy v podobe zamrznutia aplikácie a kvôli tomuto faktu aplikácia nie je ďalej využívaná v práci.

Sparkvue [24]

Sparkvue 3.1.1.4 funguje na platformách Android (4.4 a vyššie), iOS a Windows. Jedná sa o aplikáciu, ktorá zbiera dáta, následne ich vizualizuje a analyzuje. Táto aplikácia umožňuje bezdrôtové spojenie s viac ako 80-timi senzormi od firmy PASCO (taktiež vývojár aplikácie). Nazbierané dáta sa dajú zobrazíť v grafoch, stĺpcových grafoch a v tabuľkách. Následne môžeme nazbierané dáta zo senzorov analyzovať prostredníctvom funkcií ako sú: min, max, priemer, smerodajná odchýlka. V rámci mobilných senzorov zhromažďuje a zobrazuje dáta z akcelerometru a zo zvukových snímačov. Aplikácia podporuje až 28 jazykov vrátane slovenčiny. Vzorkovacia frekvencia siaha od jednej vzorky za 4 hodiny až po 4 kHz. Export dát je vo formáte *.CSV. Aplikácia neumožňuje odpočet gravitačného zrýchlenia.

Accelerometer Analyzer [25]

Aplikácia Accelerometer Analyzer 16.11.27 od vývojára Mobile Tools vyžaduje Android 2.3 a vyšší. Aplikácia nemá podporu pre iOS. Ako jedna z mála aplikácií umožňuje odčítanie gravitačného zrýchlenia, zmeniť jednotku merania a to buď v $[m/s^2]$, v jednotkách [g] alebo v $[stopách/s^2]$. Ako nevýhoda sa pokladá nastavenie vzorkovacej frekvencia, ktorá sa nedá nastaviť na konkrétnu hodnotu v určitom intervale. Avšak namiesto toho vývojári poskytujú 4 módy snímania a to buď 5/15/50/100 vzoriek za sekundu. Export dát je vo formáte *.TXT poprípade sa môžu dáta zazipovať pre šetrenie ukladacieho priestoru. Aplikácia ponúka aj možnosť zmeniť formu zápisu a to tak, že si osoba dokáže nastaviť čím budú hodnoty x, y a z os oddelené (medzerou/čiarkou/bodkočiarkou). Táto možnosť sa pokladá za veľké plus kedy sa nemusí oddelenie meniť dodatočne ručne. Aplikácia výborne funguje aj na pozadí avšak

pri zablokovaní telefónu prestáva snímať. Ako ďalšiu možnosť sa uvádza výpočet RMS (Root Mean Square) resp. kvadratický priemer. RMS je odmocnina zo súčtu štvorcov jednotlivých hodnôt predelená počtom meraní. Vzhľadom na to, že aplikácia dokáže aktivovať alarm po prekročení určitej nastaviteľnej hodnoty môže sa využívať aj ako detektor vibrácií. Po zakúpení plnej verzie aplikácia poskytuje mnoho ďalších nastavení (výpočet stredných hodnôt, nastavenia oneskorení, ...). Accelerometer Analyzer je druhou testovanou aplikáciou tejto práce.

3 SNÍMANIE DÁT

Snímanie ľudskej aktivity je možné viacerými spôsobmi. Medzi faktory snímania patrí umiestnenie snímacieho zariadenia a typ snímacieho zariadenia.

Výber umiestnenia snímacieho zariadenia je závislý na účele snímania. V prípade snímania vysokej aktivity ako je beh, chôdza je ideálne umiestnenie na členku. Príkladom zariadenia, ktoré sníma kroky s umiestnením na členku je Step-Watch 3. Jeho presnosť sa určuje v hranici 1-2 %[3]. Avšak pri umiestnení zariadenia na členok je potrebné brať do úvahy možné výkyvy nohy, ktoré nemusia byť spôsobené kráčaním (pohyby nohy počas sedenia)[3]. Ako ďalšie možnosti umiestnenia sa pokladá umiestnenie na stehennom svale, páse a dokonca aj na zápästí. Pri umiestnení na zápästí je problémové snímanie pokiaľ je zápästie počas kráčania v stacionárnej polohe a naopak tu môže dochádzať ku vysokým akceleračným pohybom, ktoré by zvýšili počet falošných krokov [14].

V prípade snímania strednej aktivity ako sú napríklad bežné činnosti v domácnosti nie je vždy umiestnenie na členku vyhovujúce. Pri tomto umiestnení nie sme schopný rozlíšiť ani státie od sedenia, preferujúce umiestnenie sa pokladá hrud' alebo zápästie [14].

V prípade nízkej aktivity (ľah) je preferujúce umiestnenie zápästie a ucho [14]. Okrem toho presná orientácia snímacieho zariadenia bude závisieť nie len od umiestnenia, ale aj od telesného tvaru nositeľa a odevu, ku ktorému bude prístroj pripevnený [26].

Ideálnym prípadom by bolo použitie čo najviac senzorov pripevnených na rôznych častiach tela s cieľom snímania aj najmenších zmien v aktivitách. Vďaka tomu by sa docielila presnejšia klasifikácia dennej aktivity. Na druhej strane použitie viacerých snímacích zariadení môže spôsobiť problém s nositeľnosťou a môže nakoniec ovplyvniť výsledky snímania. Príkladom môže byť umiestnenie zariadení na lýtku. Vzhľadom na to, že toto zariadenie musí byť upevnené pevne aby nedochádzalo ku nepriaznivým pohybom zariadenia po určitom časovom úseku dochádza ku bolesti lýtkového svalu a teda aj ku nepriaznivým zmenám typu chôdze. Preto je snaha o minimalizáciu počtu používaných snímacích zariadení [14].

3.1 Testovanie Fitbit Alta HR

Na obrazovke OLED sú zobrazované hodnoty, avšak tieto hodnoty nie sú okamžité. Nie je jasné ako dochádza ku aktualizáciám dát (za určitý časový interval / dosiahnutie určitého počtu krokov). Aktualizácia za určitý časový interval je logická avšak na základe testovania sa nedokáže vyvrátiť ani potvrdiť. Na začiatku testovania bolo nasnímaných 0 krokov. Vykonal sa 150 krokov, na OLED obrazovke bola hodnota 129 krokov. Pokiaľ by sa zariadenie aktualizovalo s časovým intervalom napr. 10 minút a aktivita bude snímaná 15 minút, výsledná hodnota krokov by sa mala získať po 20 minútach od začiatku snímania aktivity. V testovaní sa v časovom úseku 1 hodiny sa hodnota 129 krokov nezmenila. Pričom pri predpoklade aktualizácie za určitý časový interval sa

očakávala dodatočná zmena počtu krokov. Na základe tohto testovania je možná aj aktualizácia po dosiahnutí určitého počtu krokov/ dĺžke aktivity.

Aj napriek tomu, že je odporúčané nosenie zariadenia na nedominantnej ruke [7] sa môže predpokladať, že tu dochádza ku falošne pozitívnym výsledkom. V rámci testovania tohto zariadenia osoba stála avšak vykonávala aktivitu rukami. Zariadenie započítalo 63 krokov. Tento údaj sa avšak nemôže automaticky brať ako chybný. Môže to byť aj spôsobené neskorším započítaním predchádzajúcich krokov.

3.2 Signál pre hodnotenie vytvorených algoritmov

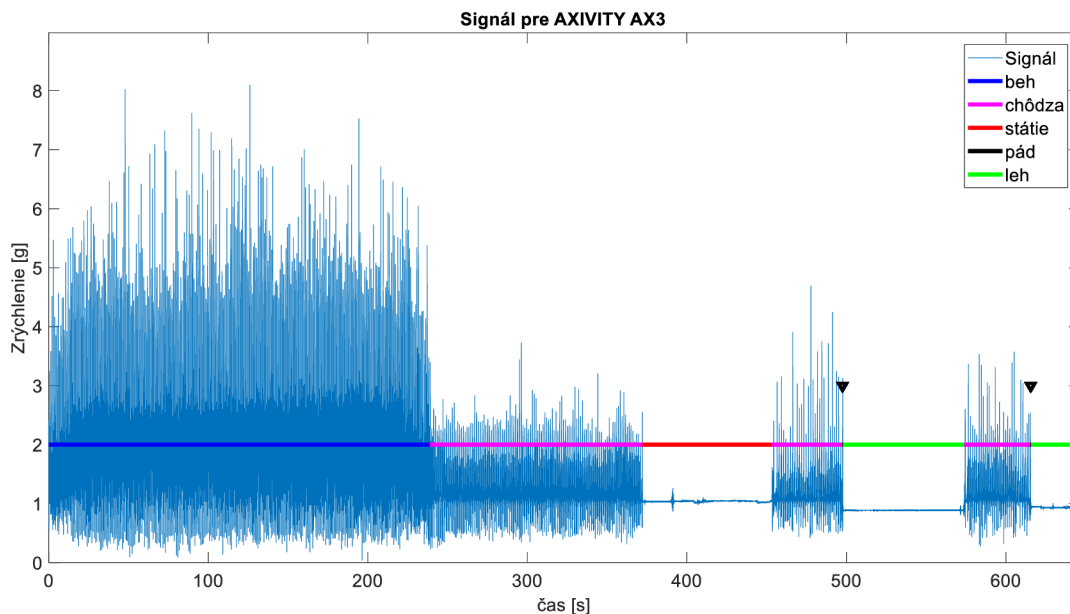
V praktickej časti sme využívali signály nasnímané pomocou zariadenia Axivity AX3 a chytrého telefónu. V prípade chytrého telefónu sa použili aplikácie Sense – it 1.1 Beta 14 a Accelerometer Analyzer 16.11.27. Cieľom nasnímania aktivít rôznymi zariadeniami je ich vzájomné porovnanie a určenie ich presností. Porovnanie sa vykoná využitím rovnakých algoritmov pre obidva zariadenia. Vzhľadom na to, že sa nejedná o dlhotrvajúce snímanie zvolila sa $f_{vz} = 50$ Hz pre všetky nasnímané signály. Pre dlhšie signály (signály trvajúce hodinu a viac) je výhodnejšie použiť menšiu f_{vz} z dôvodu veľkého množstva dát. Pretože všetky merané pohyby teda sú obsiahnuté vo frekvenciách pod 20 Hz [11]. Zvyčajne sa používa vzorkovacia frekvencia v rozmedzí 20 Hz až 50 Hz [12].

Pre každú aktivitu sa vybrala farba, ktorá reprezentuje aktivitu v referenciách a vo výsledkoch. Konkrétne priradenie farieb ku aktivitám sa nachádzajú v tabuľke číslo 3.1.

Tabuľka 3.1 Priradenie farieb pre aktivity


Farba	Aktivita
magenta	chôdza
červená	státie/sedenie
čierna	pád
modrá	beh
svetlá zelená	ľah

Signál použitý pre hodnotenie dennej aktivity je zobrazený na obrázku číslo 3.1. Jedná sa o cca. 11 minútový záznam, v ktorom sú vykonávané aktivity ako je beh, chôdza, státie, ľah a pád. Pred behom sa snímaná osoba plynulo rozbiehala a následne pokračoval beh, chôdza, státie, chôdza, pád, ľah, chôdza, pád a znovu ľah. Ku koncu signálu nachádzame artefakty spôsobené ukončením snímania. Dané aktivity sú zvýraznené v signále. Môžeme to pokladať ako referenčné hodnoty.



Obrázok 3.1 Signál (SVM) pre hodnotenie aktivity prostredníctvom modifikovaného algoritmu detekcie pádu

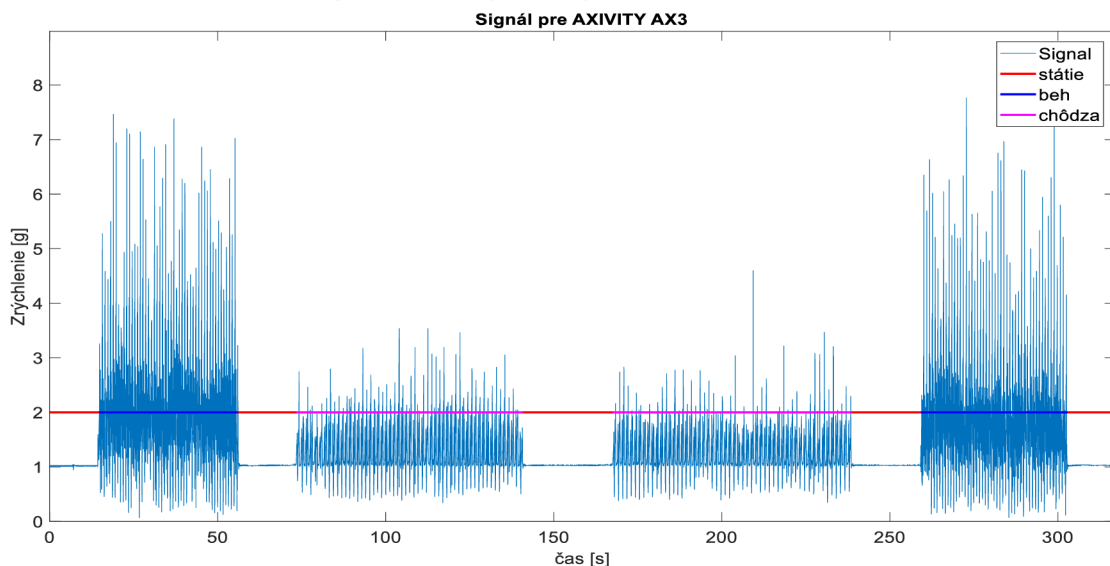
Dĺžka pádu je v rámci sekúnd a nie je viditeľná na obrázku číslo 3.1 preto obrázok číslo 3.2 zobrazuje detail tejto aktivity. Ako je aj viditeľné zo signálu pri chôdzi je viditeľná periodickosť zatiaľ čo pád je špecifický abnormálnym píkom. [11]



Obrázok 3.2 Priblíženie aktivity pádu

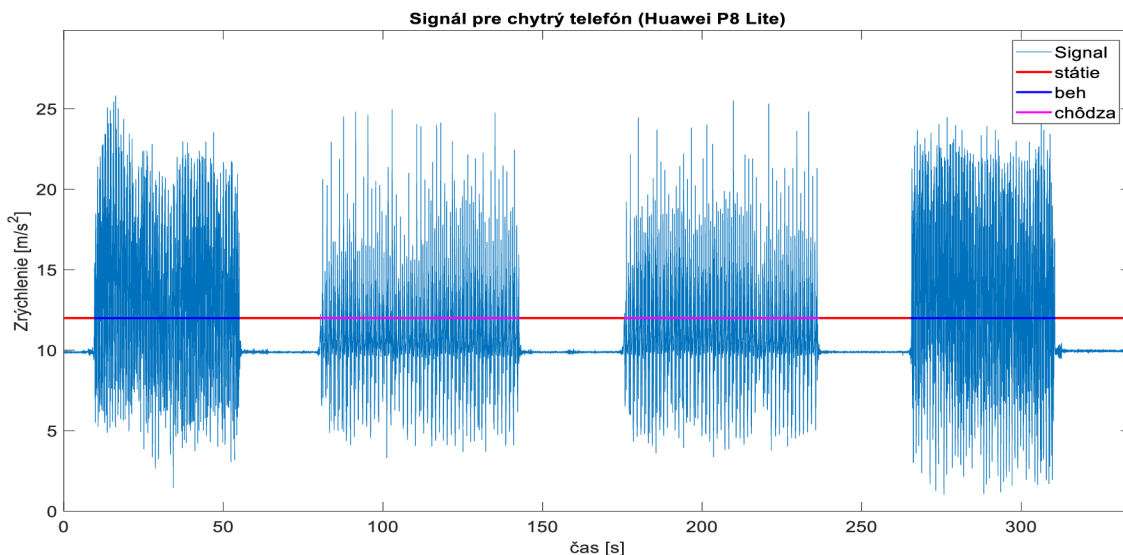
Signály využívané pre detekciu krokov sú zobrazené na obrázkoch číslo 3.3 a 3.4. Umiestnenie Axivity AX3 a chytrého telefónu bolo na nohe (Axivity AX3 – členok, chytrý telefón – lýtkový sval). Snímaná osoba spočiatku stála následne sa rozbehla, zastavila, kráčala, zastavila, kráčala, zastavila, bežala a nakoniec zastavila. Snímaný signál je pomocou státia rozdelený na 4 úseky: státie-beh, státie-chôdza, státie-chôdza a státie-beh. Pričom posledné státie bolo využité pre ukončenie snímania. Pre uľahčenie

počítania krokov a hodnotenia detekcie osoba v každom úseku vykonala presne 100 krokov. Celkovo v tomto signále bolo vykonaných teda 400 krokov.



Obrázok 3.3 Signál (SVM) pre hodnotenie prostredníctvom krokomeru

Pomocou chytrého telefónu a aplikácie Sense it sa nasnímal signál s rovnakými aktivitami ako prostredníctvom Axivity AX3. Tento signál je zobrazený na obrázku číslo 3.4. Signál je taktiež rozdelený na 4 úseky a v každom úseku je vykonaných 100 krokov. Celkový počet krokov je teda taktiež 400.



Obrázok 3.4 Signál (SVM) pre hodnotenie prostredníctvom krokomeru


3.3 Signály pre porovnanie zariadení

V tejto kapitole sú zobrazené a popísané signály, ktoré slúžia ku porovnaniu zariadení a aplikácií. Signály sú snímané súčasne dvoma zariadeniami a to Axivity AX3 a chytrým telefónom (Huawei P8 Lite). V prípade snímania signálu chytrým telefónom sú porovnávané aplikácie Sense it a Accelerometer analyzer, ktoré sa nachádzajú popísané


v kapitole 2.2. Signály sú nasnímané na rôznych častiach tela (noha a biceps) s rôznymi vzorkovacími frekvenciami (25, 50 a 100 Hz). Pre každú kombináciu umiestnenia, vzorkovacej frekvencie a aplikácie je nasnímaných viacero signálov pre spoľahlivejšie určenie presnosti. S ohľadom na robustnosť analýzy nemôžu byť v tejto práci popísané všetky nasnímané a analyzované signály. Z tohto dôvodu boli vybrané kombinácie, na ktorých je možné zobrazit' rozdiely v nasnímaných signáloch. Dáta z chytrého telefónu sú snímané v jednotkách m/s^2 , zatiaľ čo Axivity AX3 v jednotkách g. Preto pred zobrazením boli pre lepšiu viditeľnosť rozdielov dáta z chytrého telefónu prevedené na jednotky g. Vykonávané aktivity sú vždy zvýraznené v signály pomocou farebných čiar.

Na obrázku 3.5 je signál nasnímaný prostredníctvom Axivity AX3, s umiestnením na členku. Obrázok 3.6 zobrazuje signál nasnímaný prostredníctvom chytrého telefónu – aplikácie Sense it. Umiestnenie chytrého telefónu na členok je nevhodné z dôvodu nestability zariadenia a zároveň pri súčasnom umiestnení dvoch zariadení v tesnej blízkosti dochádza ku vzájomnej interferencii. Táto interferencia je spôsobená vzájomným trením zariadení. Vzhľadom na tieto fakty bolo umiestnenie chytrého telefónu na lýtkovom svale. Vzorkovacia frekvencia nasnímaných signálov je 50 Hz.

Najväčší rozdiel je v amplitúdach zrýchlenia. Dôvodom tohto rozdielu je umiestnenie zariadení, kedy kmit nohy je v členku väčší ako kmit na lýtkovom svale. Pri zmene polohy Axivity AX3 na lýtkový sval sa očakáva približne rovnaká hodnota amplitúd zrýchlenia.

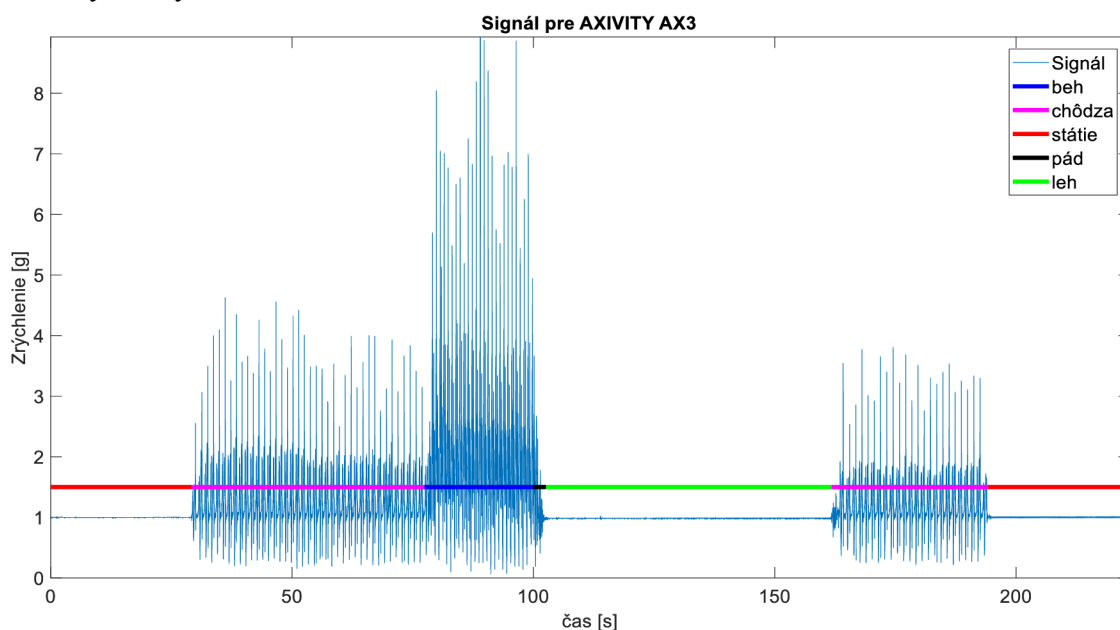


Obrázok 3.5 SVM testovacieho signálu 1 (Axivity AX3, členok, 50 Hz)

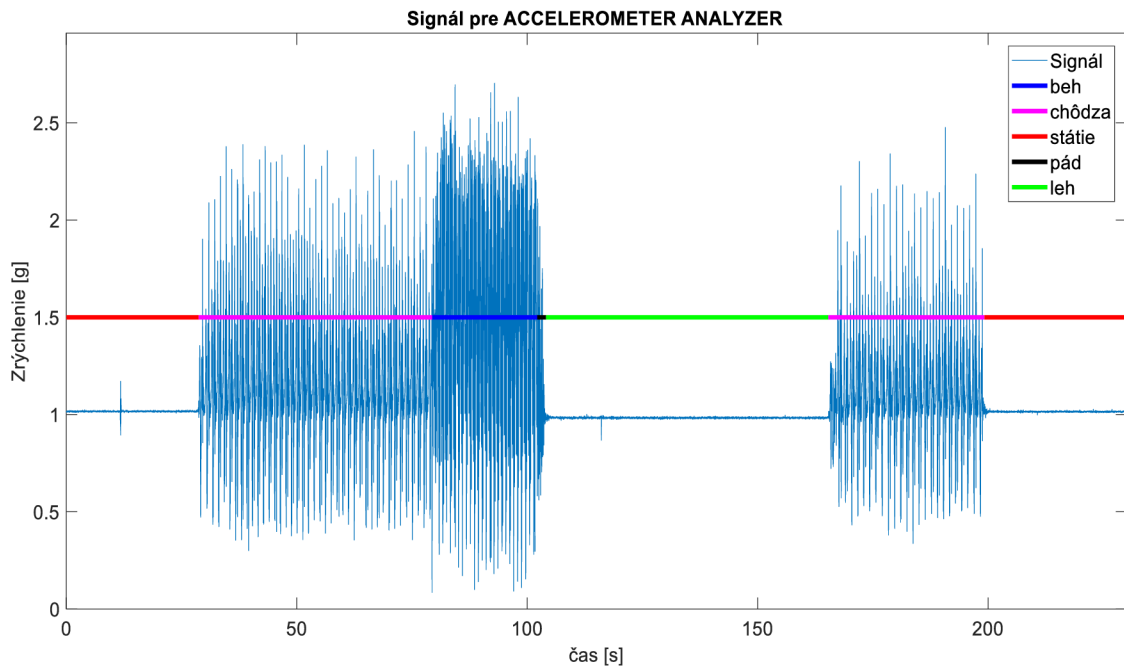


Obrázok 3.6 SVM testovacieho signálu 1 (aplikácia Sense it, lýtkový sval, 50 Hz)

Obrázky 3.7 a 3.8 vykresľujú signály nasnímané prostredníctvom Axivity AX3 a aplikácie Accelerometer Analyzer. Vysvetlenie rozdielu medzi amplitúdami je totožné ako v prípade signálu 1. Rozdiel amplitúd medzi aplikáciami Sense it a Accelerometer Analyzer sa nevyskytuje. V prípade snímania pomocou aplikácie Accelerometer Analyzer dochádza ku vzniku artefaktov v podobe malých prekmitov v období klúdu (obrázok 3.8 cca 15 a 115 sekunda záznamu). Tieto artefakty sú spôsobené prichádzajúcou správou, ktorá spôsobila vibráciu telefónu a teda aj vznik krátkych falošných prekmitov. Badateľný rozdiel v použití rôznych vzorkovacích frekvencií nie je viditeľný voľným okom.

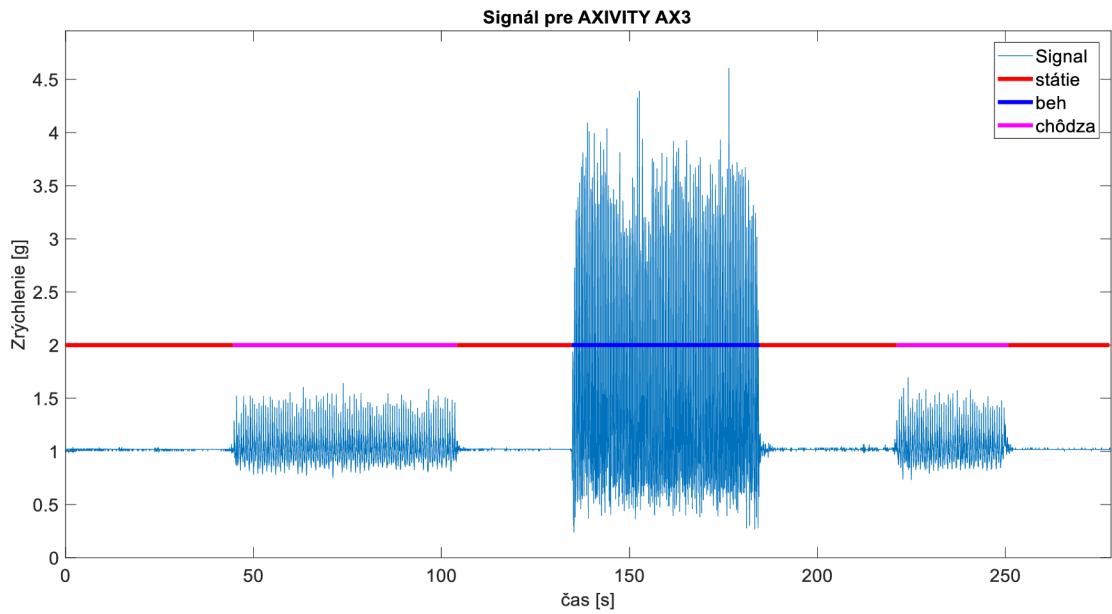


Obrázok 3.7 SVM testovacieho signálu 24 (Axivity AX3, členok, 100 Hz)




Obrázok 3.8 SVM testovacieho signálu 24 (Accelerometer Analyzer, lýtkový sval, 100 Hz)

Testovací signál číslo 46 nasnímaný prostredníctvom Axivity AX3 (obrázok 3.9) a aplikácie Sense it (obrázok 3.10), s umiestnením na bicepse a so vzorkovacou frekvenciou 25 Hz bol vybraný ako posledná kombinácia zobrazujúca rozdiely medzi nasnímanými signálmi. Tento signál je vykreslený z dôvodu zobrazenia rozdielov medzi snímaním na bicepse a členku. Najväčší rozdiel pri snímaní s Axivity AX3 je v amplitúde zrýchlenia, zatiaľ čo pri snímaní s umiestnením na členku sa tieto hodnoty nachádzajú v rozmedzí 0-10 g, v prípade umiestnenia na bicepse rozsah hodnôt je polovičný a preto očakávame hodnoty zrýchlenia od 0-5 g. Táto skutočnosť je spôsobená faktom, že pri chôdzi je kmit ruky menší ako vykonanie samotného kroku. V prípade snímania chytrým telefónom je zmena amplitúdy zrýchlenia viditeľná iba vo vykonávanej chôdzi, odôvodnením je umiestnenie na lýtkovom svale. Pri chôdzi osoba prirodzene nevykonáva výrazné kmity rukou, zatiaľ čo pri behu kmity ruky spôsobujú amplitúdy zrýchlenia približne rovnaké ako kmity nohy. Ako je aj na tomto signály badateľné v prípade snímania chytrým telefónom dochádza ku krátkodobým výpadkom snímania. Tento výpadok je pozorovateľný v obrázku 3.8 úsek 90 sekúnd. Príčina tohto výpadku nie je známa.



Obrázok 3.9 SVM testovacieho signálu 46 (Axivity AX3, biceps, 25 Hz)



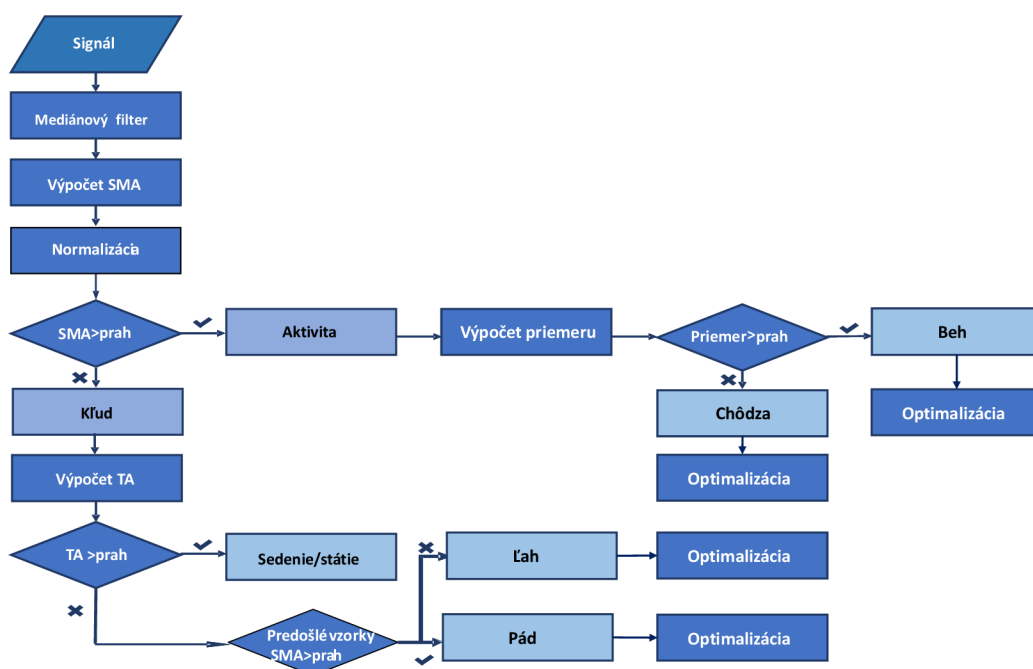
Obrázok 3.10 SVM testovacieho signálu 46 (aplikácia Sense it, biceps, 25 Hz)

4 ALGORITMUS PRE HODNOTENIE AKTIVITY

Detailné a presné meranie fyzickej aktivity osoby je kľúčová požiadavka pre výskumných pracovníkov, ktorý sa snažia pochopiť vzťah medzi zdravím a fyzickou aktivitou [27]. Akcelerometre sú dnes bežne používanými zariadeniami pre meranie fyzickej aktivity či už vo výskumných alebo v komerčných zariadeniach [28]. Ohodnotenie získaných údajov z akcelerometru je náročné. V tejto kapitole sú popísané tri metódy ohodnotenia získaných údajov: rozšírený algoritmus, ktorý vychádza z detekcie pádu [10] a algoritmy krokometru. Všetky algoritmy sú prispôbené viacerým vzorkovacím frekvenciám a umiestneniam na bicepse a nohe.

4.1 Rozšírený algoritmus detekcie pádu

Jedna z navrhnutých a realizovaných metód pre hodnotenie ľudskej aktivity využíva modifikovaný algoritmus pre detekciu pádu [10]. Avšak v tomto algoritme sa nedetekuje len pád, ale aj aktivity ako je beh, chôdza, ľah, sedenie. Schéma algoritmu je zobrazená na obrázku číslo 4.1. Počiatočná mediánová filtrácia, výpočet SMA (Signal magnitude area) a výpočet TA (Tilt angle) vychádzajú z článku [10] ostatné časti algoritmu sú navrhnuté autorkou tejto práce.



Obrázok 4.1 Bloková schéma modifikovanej verzie detekcie pádu

Ako prvé je potrebné signál nasnímať. Pri tejto metóde je dôležité umiestnenie snímacieho zariadenia. Pri samotnej detekcii pádu sa hlava a pás pokladajú za preferujúce umiestnenia [10]. Vzhľadom na to, že v tomto algoritme dochádza ku hodnoteniu aj ostatných aktivít vybralo sa umiestnenie na nohe. Zo snímacieho

zariadenia sa zhromaždia údaje o X, Y a Z os, ktoré sa následne spracúvajú v prostredí Matlab R2017b.

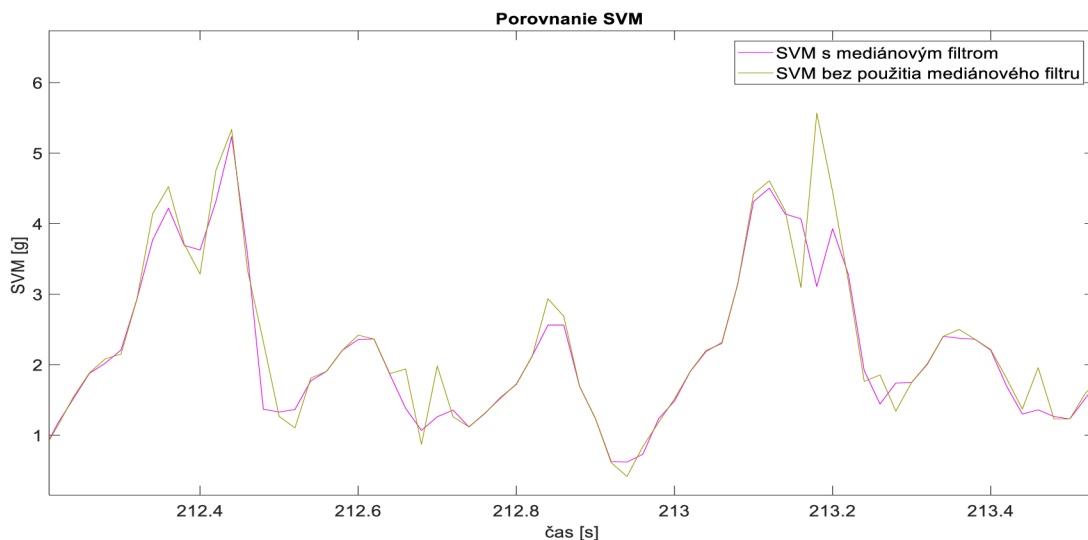
Všetky nasnímané aktivity tela sa nachádzajú vo frekvenčnej oblasti do 20 Hz [10], [14]. Na nazbierané surové dáta je potrebné implementovať mediánový filter s oknom $w = 3$ vzorky. Medianový filter je vhodný na potlačanie impulzného šumu. Za jeho výhody sa pokladá zachovávanie hrán a súčasná redukcia náhodného šumu. Implementácia tohto filtru do signálu zabezpečí odstránenie abnormálnych impulzov, ktoré produkuje snímacie zariadenie a nie sú spôsobené ľudskou aktivitou. Táto filtrácia sa vykoná na všetky os zvlášť a následne je vypočítané SVM (Signal magnitude vector). SVM je vypočítané len pre lepšie zobrazenie rozdielov pred a po filtrácii, pre samotný algoritmus sa ďalej nevyužíva.

SVM alebo tiež SV (Sum vector) (1) sa používa na vyhodnotenie stupňa intenzity pohybu a je najčastejšie používaným parametrom na odvodenie prahových hodnôt zrýchlenia pre rozlíšenie aktivity a kľudu [11], [14]. Vďaka spojeniu všetkých osí pomocou výpočtu SVM nie je potrebné riešiť vplyv gravitačného zrýchlenia na každú os zvlášť (natočenie snímacieho zariadenia).

$$SVM(i) = \sqrt{x_i^2 + y_i^2 + z_i^2} \quad (1)$$

kde x_i , y_i a z_i reprezentuje i -tú vzorku.

Výsledok filtrácie je vykreslený na obrázku číslo 4.2. Zobrazený úsek odpovedá aktivite behu snímaného pomocou zariadenia Axivity AX3. Výstup tohto filtru je následne použitý pre ďalšie spracovania [11].



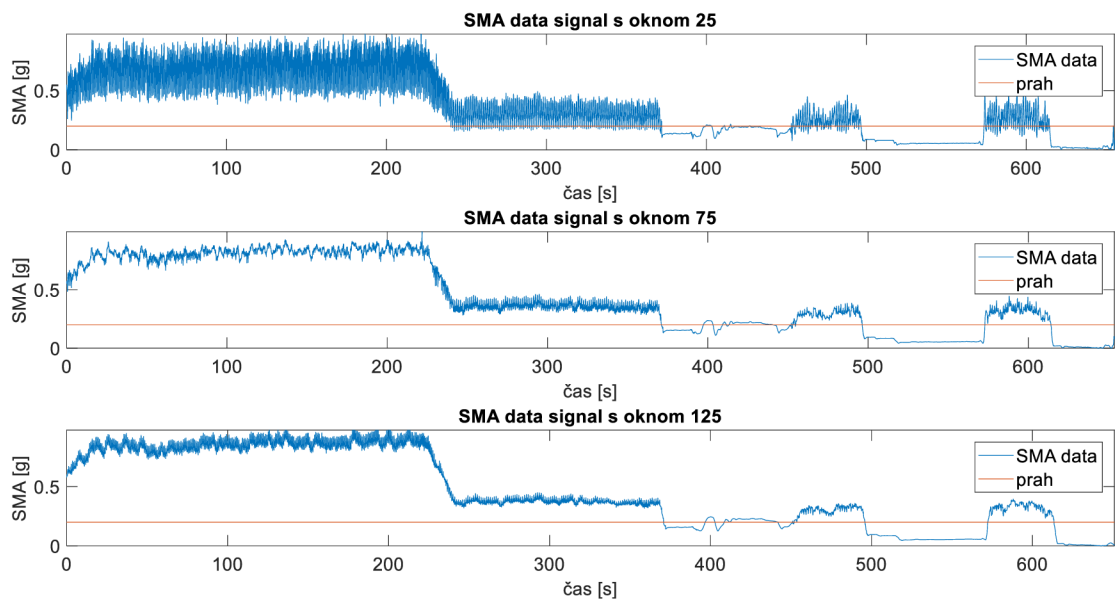
Obrázok 4.2: Porovnanie SVM s použitím a bez použitia mediánovej filtrácie

Po počiatočnej filtrácii signálu nasleduje výpočet SMA (Signal magnitude area) (2) [29]. SMA patrí medzi základné výpočty, ktoré pomáhajú rozlíšiť časové úseky odpočinku a aktivity, charakterizuje mieru zmeny ľudského pohybu teda čím väčšia hodnota tým prudšie zmeny aktivity osoby [10], [11], [26].

$$SMA(w) = \frac{1}{w} \left(\sum_{i=1}^w |x_i| + \sum_{i=1}^w |y_i| + \sum_{i=1}^w |z_i| \right) \quad (2)$$

kde x_i , y_i a z_i reprezentuje i -tá vzorka signálu os x , y , z v zvolenom plávajúcom okne o dĺžke w .

Obrázok 4.3 nám zobrazuje rozdiely pri zvolení okna $w = 25$ vzoriek, $w = 75$ vzoriek a $w = 125$ vzoriek. V tomto algoritme bola vybraná veľkosť okna 75 vzoriek. Pri voľbe okna veľkosti 25 vzoriek nedochádza ešte ku dostatočným oddeleniam aktivít a pri okne veľkosti 125 vzoriek síce dochádza na pohľad ku „čistejšiemu“ signálu avšak zároveň dochádza aj ku skresleniu prechodov medzi jednotlivými aktivitami, čo môže viesť ku neschopnosti detekovať pád.



Obrázok 4.3 Porovnanie SMA pri rôznych veľkostiach okna $w = 25$ vzoriek, $w = 75$ vzoriek a $w = 125$ vzoriek

Po výpočte SMA bola prevedená normalizácia dát prostredníctvom vzorcu (3) [30]. Táto normalizácia je potrebná z dôvodu rozdielneho rozsahu amplitúd pri meraní prostredníctvom telefónu a Axivity AX3. Normalizovaný signál má rozsah od $\langle 0,1 \rangle$. Vďaka normalizácii bude možné posúdiť či sa jedná o aktivitu alebo kľud prostredníctvom jednej hodnoty prahu. Na základe empirických znalostí sa stanovil prah na hodnotu 0,2 (prahSMA = 0,2, zobrazený na obrázku 4.3). Na základe tejto prahovej hodnoty je možné rozlíšiť aktivitu od kľudu.

$$SMA_{Norm.}(i) = \frac{SMA(i) - \min(SMA)}{\max(SMA) - \min(SMA)} \quad (3)$$

V prípade nižšej hodnoty ako je stanovený prah sa predpokladá, že osoba buď nevykonáva aktivitu teda je v kľude alebo osoba padla. Pokiaľ je osoba v kľude

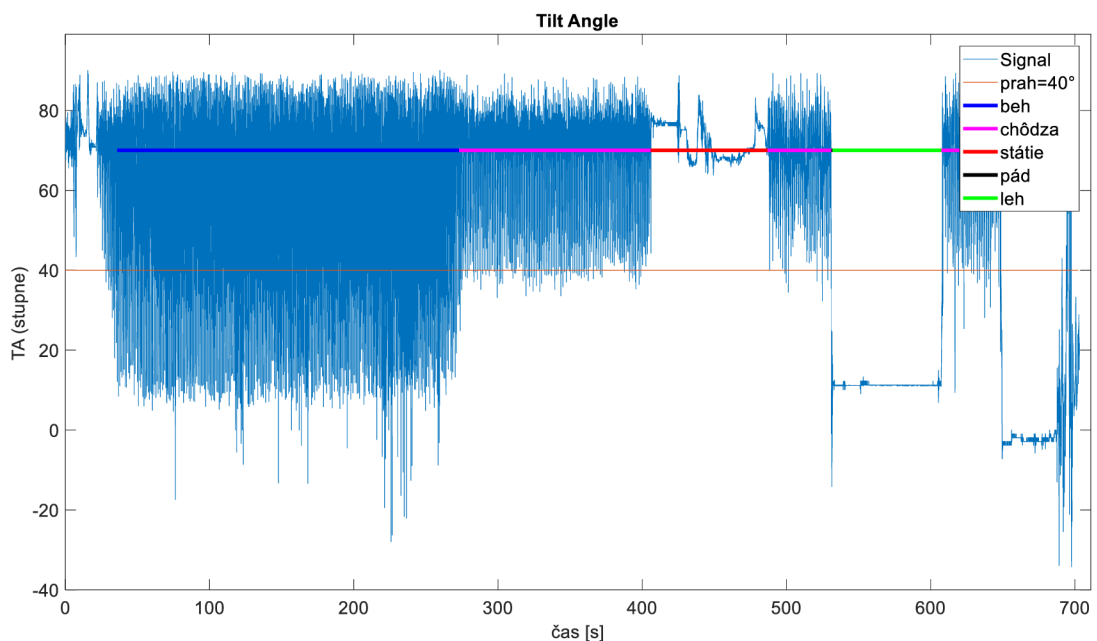
klasifikujeme jej aktivitu ďalej na sed, pád, ľah alebo státie. Pre rozpoznanie týchto aktivít sa použil výpočet uhlu sklonu TA (tilt angle) (4). [10]

$$TA(i) = \arcsin\left(\frac{y_i}{\sqrt{x_i^2 + y_i^2 + z_i^2}}\right) \quad (4)$$

Výsledok TA sa prevedie do stupňov (α' je veľkosť uhla v stupňoch a α je veľkosť uhla v radiánoch) (5).

$$\alpha' = \frac{\alpha \cdot 180}{\pi} \quad (5)$$


Zariadenie by malo byť umiestnené y-osou vertikálne. Tento uhol je medzi pozitívnou y osou a gravitačným vektorom g [10]. Preto pokiaľ je hodnota TA pod 40° hodnotíme túto aktivitu ako ľah/pád a naopak pokiaľ hodnota TA presahuje medzi 40° hodnotí sa táto aktivita ako státie po prípadne sedenie. Pre detekciu pádu je vytvorená podmienka. Táto podmienka sa vzťahuje na 150 predošlých vzoriek SMA (3 sekundy záznamu). Pokiaľ tieto vzorky presahujú prah SMA a po nich nasleduje ľah snímanej osoby detekuje sa pád. Zobrazenie prahu a výpočtu TA je zobrazené na obrázku číslo 4.4.



Obrázok 4.4 Tilt angle

Pokiaľ sa meria signál na členku alebo v páse nie je možné rozlíšiť státie od sedenia. Rozlíšenie týchto dvoch aktivít by bolo možné len pokiaľ by zariadenie bolo pripevnené na stehennom svale.

Prípady kedy hodnota SMA presahuje prah sa hodnotí ako vykonávanie aktivity. Ďalšie rozpoznávanie konkrétnych aktivít (chôdza, beh) sa vykonáva pomocou základnej matematickej operácie a to priemeru (6) [27]. Každá aktivita má odlišnú hodnotu priemeru. Na základe nasnímaných vzorov pomocou zariadenia Axivity AX3 (obrázok 4.5) vieme pre rôzne aktivity stanoviť hraničný priemer medzi jednotlivými aktivitami. Ako ďalšiu možnosť považujeme výpočet smerodajnej odchýlky (7) s následným dopočtom koeficientu variácie (8) [27].



Obrázok 4.5 Vzory aktivity pre stanovenie hraničného priemeru

$$\mu_s = \frac{1}{T} \sum_{i=1}^T s_i \quad (6)$$

kde s_i je i -tá vzorka signálu SMA, T je počet vzoriek.

$$\sigma_s = \sqrt{\frac{1}{T} \sum_{i=1}^T (s_i - \mu_s)^2} \quad (7)$$

kde s_i je i -tá vzorka SMA, μ_s je priemer zo signálu SMA, T počet vzoriek

$$c_v = \frac{\sigma_s}{\mu_s} \quad (8)$$

kde μ_s je priemer zo SMA, σ_s je rozptyl zo SMA, c_v je koeficient variácie SMA

Tabuľka 4.1 Priemer a variačný koeficient pre dané aktivity

Aktivita	Priemer SMA [g]	Smerodajná odchýlka SMA [g]	Koeficient variácie SMA [-]
Beh	0,6592	0,0953	0,1445
Chôdza	0,3730	0,0482	0,1293

Ako je už z tabuľky viditeľné v prípade hodnotenia aktivity zo SMA je väčší rozdiel hodnôt pri priemere ako pri koeficiente variácie. Preto sa považuje za

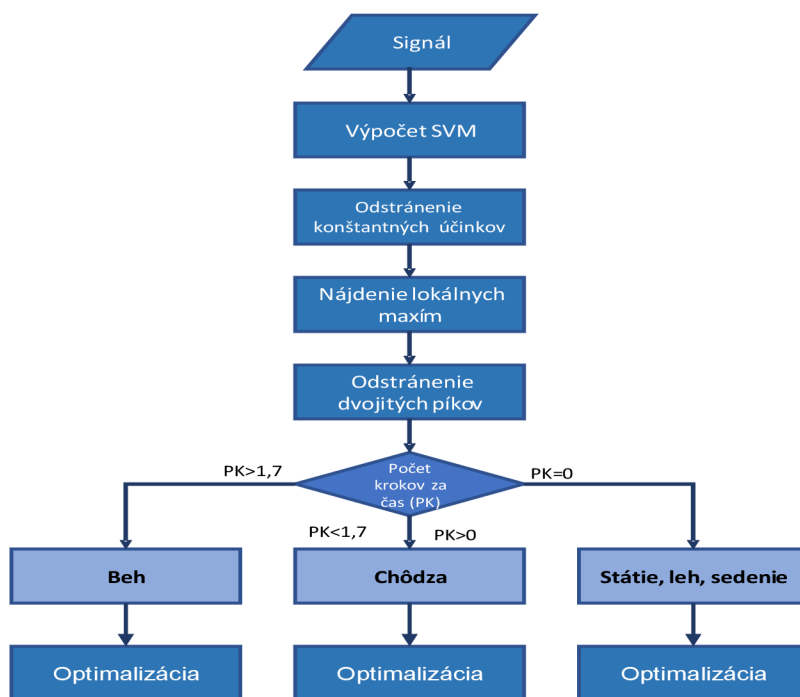
výhodnejšie použiť metódu priemeru. Na základe priemeru sme schopný rozlíšiť vertikálne aktivity a to beh, chôdza. Po detekcii všetkých aktivít nasleduje optimalizačné pravidlo: pokiaľ algoritmus detekuje vykonávanie aktivity kratšie ako 0,5 s hodnotí sa táto detekcia ako nesprávna a aktivita sa preklasifikuje na predchádzajúcu vykonávanú aktivitu. Vďaka tejto optimalizácii eliminujeme chyby detekcie, ktoré mohli byť vzniknuté neprosnosťami pri snímaní. Názorným príkladom je kedy osoba je v kľude avšak dôjde ku malému posunu snímacieho zariadenia.

4.2 Krokomer

Pomocou dát, ktoré sa získajú zo špecializovaných alebo bežne využívaných zariadení je možné realizovať pedometer (krokomer). Výstupom z krokomeru je obvykle počet krokov (PK) za istú časovú jednotku. Ideálnym umiestnením špecializovaného zariadenia je na členku popripadne na stehennom svale. V tejto práci sú navrhnuté dva algoritmy, ktoré sú popísané v podkapitole 4.2.1 a 4.2.2.

4.2.1 Krokomer 1

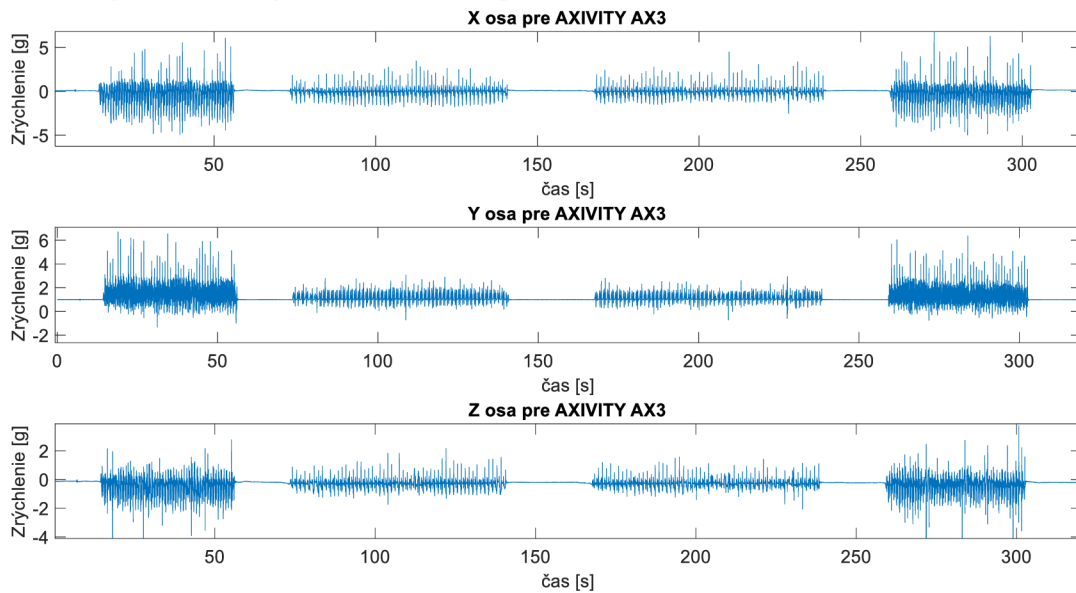
Schéma prvého navrhnutého algoritmu pre získanie počtu krokov je zobrazená na obrázku 4.6. Tento algoritmus má výpočet krokov (odstránenie konštantných účinkov, nájdenie lokálnych maxím) prevzatý z [31]. Ostatné časti algoritmu sú samostatná práca.



Obrázok 4.6 Bloková schéma pre algoritmus krokomeru

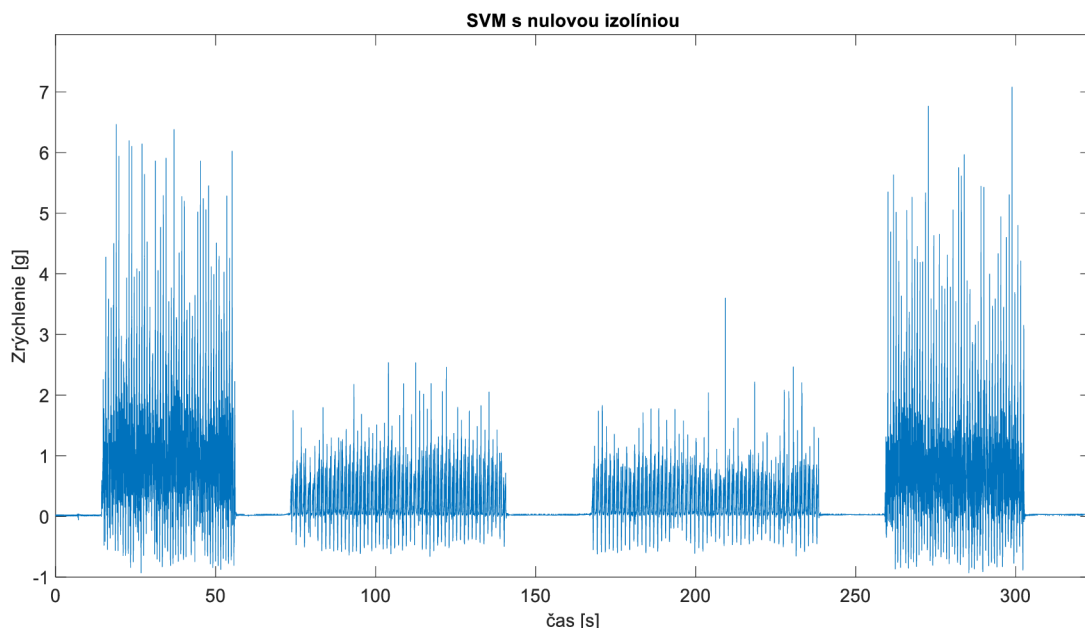
Prvým krokom hodnotiaceho algoritmu je načítanie surových dát (raw data), tieto dáta sa spoja v jeden vektor a to na základe výpočtu SVM (2) [11], [14].

Zobrazenie surových dát je na obrázku 4.7. Zobrazenie SVM dát bez odčítania konštantných účinkov je zobrazené v kapitole 3.2



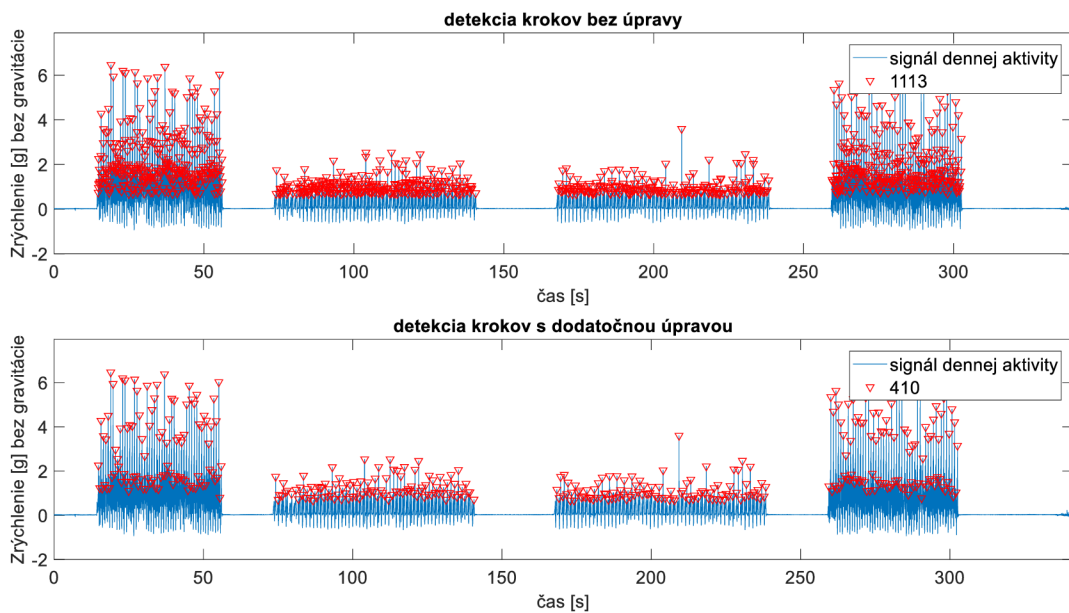
Obrázok 4.7 Raw dáta zo špecializovaného zariadenia (X, Y, Z os)

Z grafov vyplýva, že základná línia nie je nulová a preto sa vykoná buď odčítanie priemerov a tým sa odstránia konštantné účinky ako je napríklad gravitácia alebo sa vykoná odčítanie konkrétnej hodnoty zrýchlenia, v ktorej akcelerometer meria čo je v tomto prípade 1G [31], [9]. Touto úpravou sa získa čistý signál očistený od gravitačného zrýchlenia, externých vibrácií a iných zložiek, ktoré sú produkované špecializovaným zariadením a nie pohybom tela [31]. Priemer signálu je 1,4702 g, preto jeho odpočtom sa nezíska nulová izolínia. Na obrázku číslo 4.8 je zobrazený signál po odčítaní 1 g.



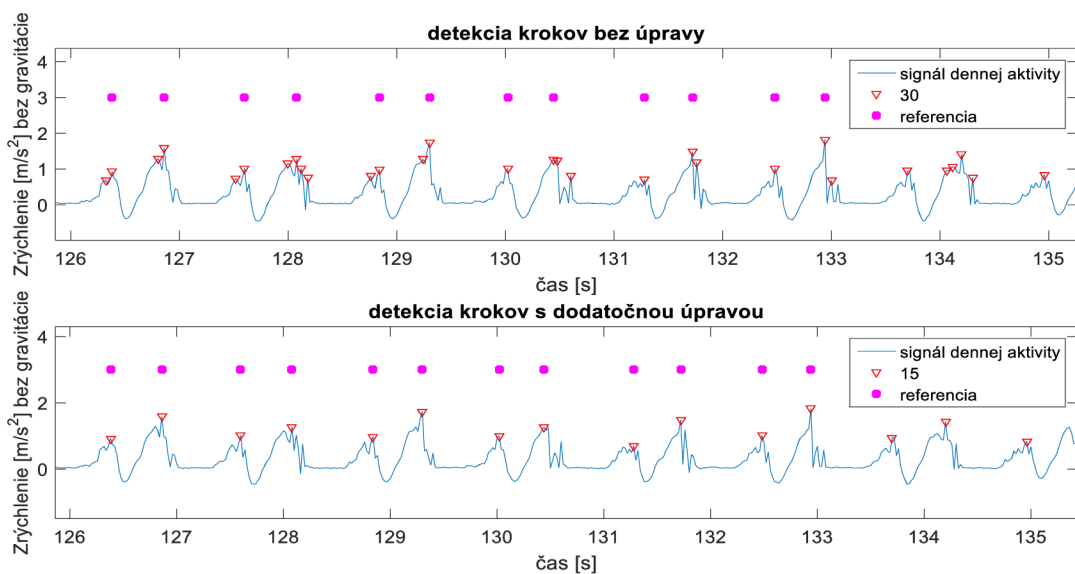
Obrázok 4.8 Výsledok výpočtu SVM s nulovou izolíniou

Následne sa nájdu lokálne maximá. Je potrebné stanoviť hodnotu minimálnej výšky píku - smerodajná odchýlka zo SVM. Len hodnoty nad týmto prahom sa budú považovať za krok. Pomocou dodatočnej úpravy je možné zredukovať detekovanie druhého chybného píku. Táto redukcia je zabezpečená určením minimálnej vzdialenosti za sebou idúcimi peakmi. Táto vzdialenosť bola zistená pomocou nasnímaných vzorov pre beh a chôdzu. Hodnota nastavenej vzdialenosti je 12,5 vzoriek čo odpovedá 0,25 sekundy. Rozdiel pred a po úprave spolu s počtom detekovaných krokov je zobrazený na obrázku číslo 4.9. Tento počet krokov je celkový a pre obidve nohy. Zhodnotenie oproti skutočnému počtu krokov sa nachádza v kapitole 5.2.1.



Obrázok 4.9 Detekcia krokov bez úpravy a s úpravou minimálnej vzdialenosti

Na obrázku číslo 4.10 je zobrazený detail detekcie krokov. Je zobrazených 15 krokov. Ako je viditeľné bez úpravy dochádza ku falošnej detekcii krokov.



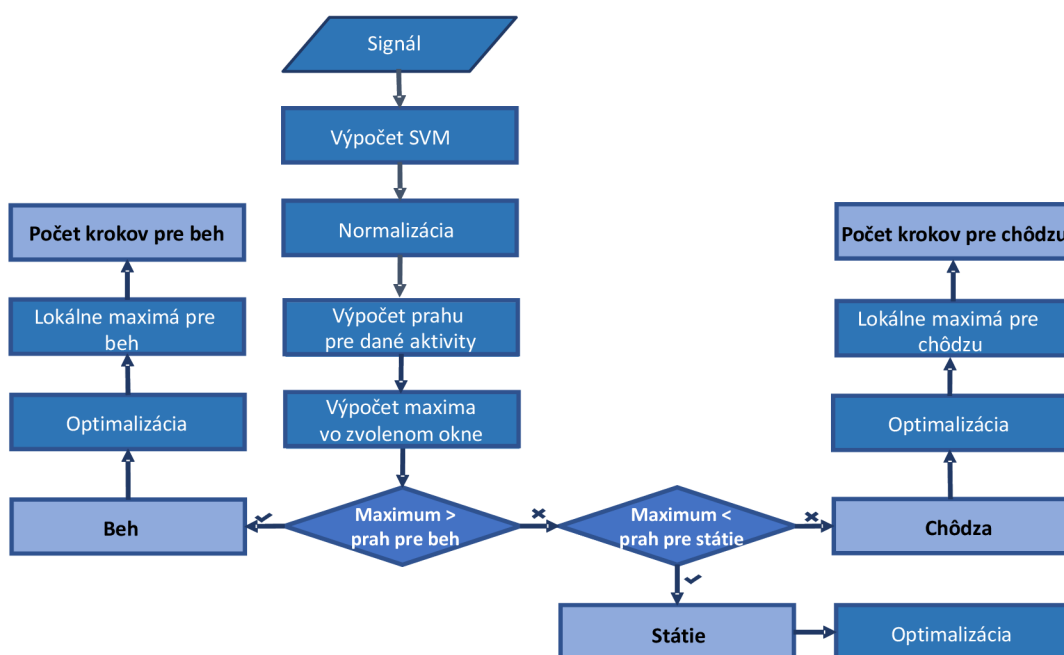
Obrázok 4.10 Detail detekcie krokov bez úpravy a s úpravou minimálnej vzdialenosti

Hodnotenie aktivity prostredníctvom krokomeru je na základe ohodnotenia počtu krokov za istý časový úsek. Na základe vytvorených vzorov pre beh a chôdzu sa zaviedlo pravidlo a to: pokiaľ je počet krokov v časovom limite 1,7 sekundy väčší ako 2 pokladá sa táto aktivita za beh, pokiaľ je hodnota väčšia ako 0,2 a zároveň menšia alebo rovná ako 2 hodnotíme túto aktivitu ako chôdzu. Pokiaľ je hodnota blízka 0 predpokladá sa, že osoba je v kľude takže sa môže jednať o státie, sedenie poprípade ľah.

Posledným krokom algoritmu je optimalizácia, ktorá funguje na podobnom princípe ako optimalizácia v prvom algoritme. Vzhľadom na to, že tento algoritmus nedetekuje rýchle zmeny polohy ako je pád bolo zavedené pravidlo: pokiaľ algoritmus detekuje činnosť, ktorá trvá kratšie ako 1,5 sekundy pokladá túto detekciu ako nesprávnu a hodnotí túto aktivitu ako poslednú vykonávanú aktivitu. Môže nastať, ale aj situácia kedy bola aktivita hodnotená správne avšak jej vykonávanie bolo kratšie ako 1,5 sekundy a vtedy algoritmus aj správnu detekciu preklasifikuje. Preto na základe tejto optimalizácií je klasifikácia algoritmu obmedzená na aktivity dlhšie ako 1,5 sekúnd.

4.2.2 Krokomer 2

Schéma krokomeru 2 je zobrazená na obrázku číslo 4.11. Jednotlivé výpočty algoritmu vychádzajú z článkov: výpočet SVM je totožný s krokomerom 1. a vychádza z článku [31], princíp normalizácie [30], odhad kvadrátu obálky [32] funkcia EMD z [33], [34], ostatné časti (určenie prahu pre dané aktivity, optimalizácia a nájdenie lokálnych maxím) sú samostatnou prácou autorky. Spojenie jednotlivých výpočtov do jedného celku je navrhnuté autorkou práce a nevychádza zo žiadneho článku.



Obrázok 4.11 Bloková schéma algoritmu krokomeru 2

Prvé kroky algoritmu (načítanie signálu, výpočet SVM) sú popísané v kapitole 4.2.1. Nasledujúcim krokom algoritmu je normalizácia dát (9), normalizácia je vykonaná z dôvodu nivelizácie rozsahu dát. Aj napriek tejto normalizácii rozsahy pre konkrétne aktivity budú rôzne pri snímaní chytrým telefónom a Axivity AX3. Dáta sú normalizované v rozsahu <0; 1,5>. Výber tohto rozsahu bol stanovený pre nedostatočné rozdiely medzi aktivitami pri testovaní rozsahu <0;1>

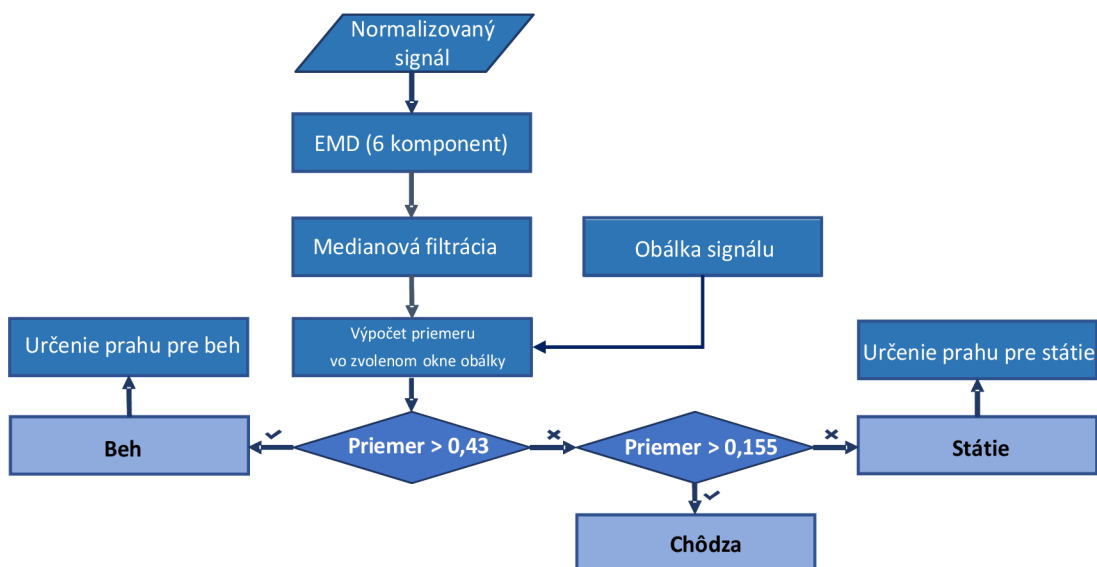
$$SVM_{Norm.}(i) = \left(\frac{SVM(i) - \min(SVM)}{\max(SVM) - \min(SVM)} \right) \cdot 1,5 \quad (9)$$

Každé snímacie zariadenie sníma v rôznych jednotkách a rozsahoch, v niektorých prípadoch nie je dostačujúca normalizácia dát. Rozdiel priemerných maxím pre aktivity je zobrazený v tabuľke číslo 4.2. Ako je z tabuľky viditeľné hodnota priemerného maxima pre chôdzi pri snímaní chytrým telefónom je vyššia ako hodnota priemerného maxima pre beh pri snímaní Axivity AX3. Pre tento fakt a presnejšiu hodnotu prahu, teda aj pre presnejšiu detekciu bol vytvorený výpočet prahu rozlíšenia aktivít pre konkrétny signál.

Tabuľka 4.2 Maximá pre aktivity nasnímané Axivity AX3 a chytrým telefónom

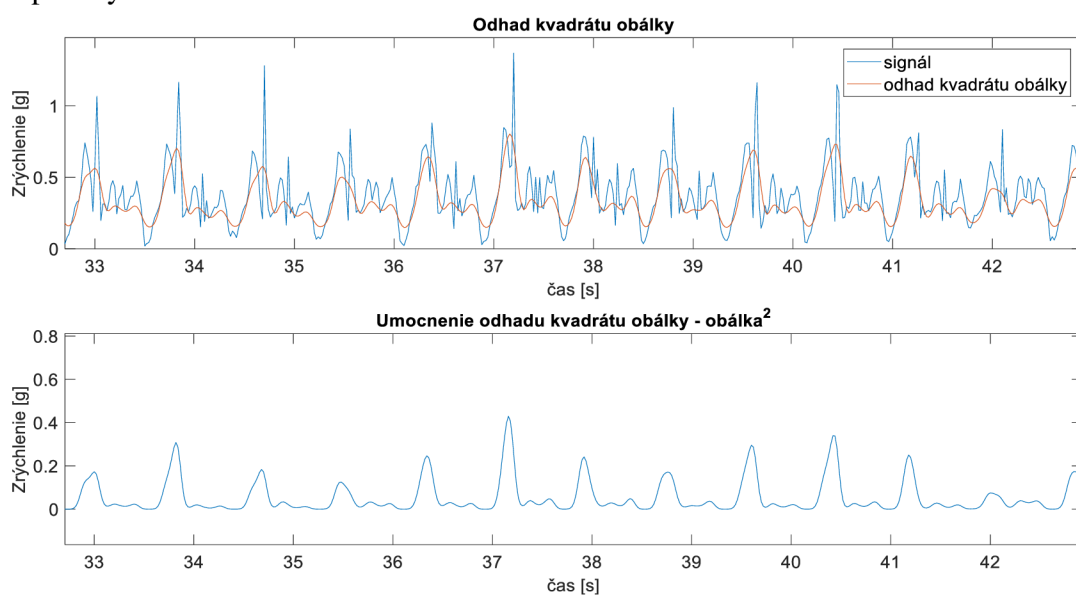
Aktivita	Axivity AX3	Chytrý telefón
Beh	0,73	1,13
Chôdza	0,33	0,99

Obrázok číslo 4.12 zobrazuje blokovú schému pre výpočet prahov. Pred výpočtom samotného prahu je vytvorený odhad kvadrátu obálky filtrovaného signálu. Tento odhad je zložený z umocnenia signálu a filtrácie LPF (lowpass filter) [32]. Výsledný odhad kvadrátu obálky spolu s následným umocnením tohto odhadu je zobrazený na obrázku číslo 4.13. Umocnením odhadu kvadrátu obálky zvýrazníme krok nohy, na ktorej je umiestnené snímacie zariadenie a zároveň potlačíme krok druhej nohy. Pre určenie prahu je potrebné rozložiť normovaný signál prostredníctvom EMD (empirická modálna dekompozícia) na 6 komponent (5 IMF a rezíduum). EMD je metóda využívaná pre rozklad ľubovoľných dát na IMF (intrinsic mode functions - vlastná modálna funkcia) [32]. IMF je funkcia, ktorá musí spĺňať dve podmienky. Prvá z podmienok hovorí o tom, že v celom súbore sa vyskytuje rovnaký počet lokálnych extrémov ako priechodov signálu nulou (maximálne odlišovať o jeden extrém), druhá podmienka je založená na predpoklade, že stredná hodnota medzi obáľkami je rovná nule (obáľka je definovaná lokálnymi maximami a minimami) [33] [34].




Obrázok 4.12 Bloková schéma pre výpočet prahov pre dané aktivity

Z EMD rozkladu sa vyberie 6-ty rozklad (rezíduum) a vykoná sa mediánová filtrácia. Mediánová filtrácia sa vykoná z dôvodu odstránenia abnormálneho prekmitnutia, ktoré vzniká pri snímaní signálu prostredníctvom telefónu. V prípade signálu nasnímanom prostredníctvom Axivity AX3 nedochádza ku prekmitnutiu a preto je mediánová filtrácia nepotrebná. Avšak pre snahu o vytvorenie všeobecného algoritmu pre obidva zariadenia sa mediánová filtrácia zaradila do bloku bez ohľadu na to akým zariadením bol signál nasnímaný. Obrázok číslo 4.14 zobrazuje rozložený signál na IMF1, IMF4 a rezíduum. V prípade rezídua je zobrazený aj prah, na základe ktorého sa určí hrubý odhad aktivity. Z hrubého odhadu rozdelenia aktivít sa vypočíta priemer pre vykonávané aktivity (beh, státie, chôdza) v obálke signálu. Nasledujúci výpočet prahov je vykonaný prostredníctvom vzorcov (10) a (11). Tieto výpočty boli stanovené empiricky.



Obrázok 4.13 Odhad kvadrátu obálky a umocnenie odhadu kvadrátu obálky




Obrázok 4.14 Rozklad signálu prostredníctvom EMD na IMF 1,4 a reziidum

$$prah_{beh} = \frac{mean_{beh} \cdot 145}{100} \quad (10)$$

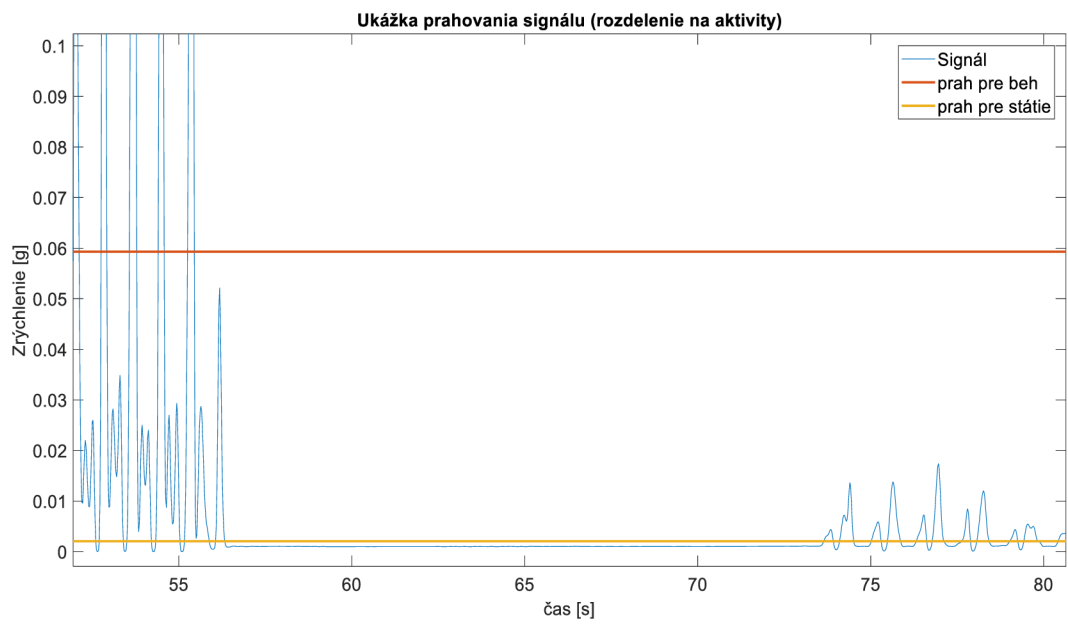
$$prah_{státie} = \frac{mean_{státie} \cdot 200}{100} \quad (11)$$

Následne sú hodnoty týchto prahov porovnávané s lokálnymi maximami v úsekoch umocnenej obálky signálu. Veľkosť týchto porovnávacích úsekov to jest, veľkosť pevného okna bola empiricky stanovená na 40 vzoriek. Pokiaľ je hodnota lokálneho maxima umocnenej obálky väčšia ako prah určený pre beh klasifikuje sa tento úsek ako beh, pokiaľ je hodnota maxima menšia ako prah pre státie klasifikuje sa státie/sedenie. Aktivita, ktorej maxima presahujú prah pre státie, ale nepresahujú prah pre beh je ohodnotená ako chôdza. Na obrázku číslo 4.15 je zobrazené toto prahovanie. Obrázok 4.16 znázorňuje priblíženie prahu pre státie.

Po klasifikácii aktivít nasleduje optimalizácia. Pribeh optimalizácie je rovnaký ako v krokometri 1. Poslednou časťou algoritmu je výpočet krokov. Tento výpočet sa vykonáva pri klasifikácii behu a chôdze podobne ako pri krokometri 1 a to prostredníctvom nájdenia lokálnych maxim v umocnenej obálke signálu. Výsledný počet krokov je pre jednu nohu konkrétne pre nohu, na ktorej je umiestnené snímacie zariadenie. Pre celkový počet krokov je potrebné tento výsledok vynásobiť dvojkou.



Obrázok 4.15 Prahovanie signálu



Obrázok 4.16 Priblíženie prahovania

5 PRESNOSŤ NAVRHNUTÝCH ALGORITMOV

Odhady chýb detekcie jednotlivých aktivít boli vypočítané prostredníctvom vzorca (12).

$$\delta = \frac{|y_n - y_s|}{y_s} \cdot 100\% \quad (12)$$

kde y_n je algoritmom určený počet vzoriek kedy sa konkrétna aktivita vykonávala, y_s je skutočný počet vzoriek kedy sa konkrétna aktivita vykonávala

Jedná sa len o odhad chýb a to z dôvodu, že nie je presne určené ohraničenie danej aktivity (nevie sa konkrétna hodnota vzorky, kedy sa vykonávanie danej aktivity začalo a ukončilo). Avšak pohľadom na nasnímaný signál je jednoduché začiatok a koniec aktivity odhadnúť a tento odhad porovnať s výsledkom detekcie [35].

5.1 Presnosť rozšíreného algoritmu detekcie pádu

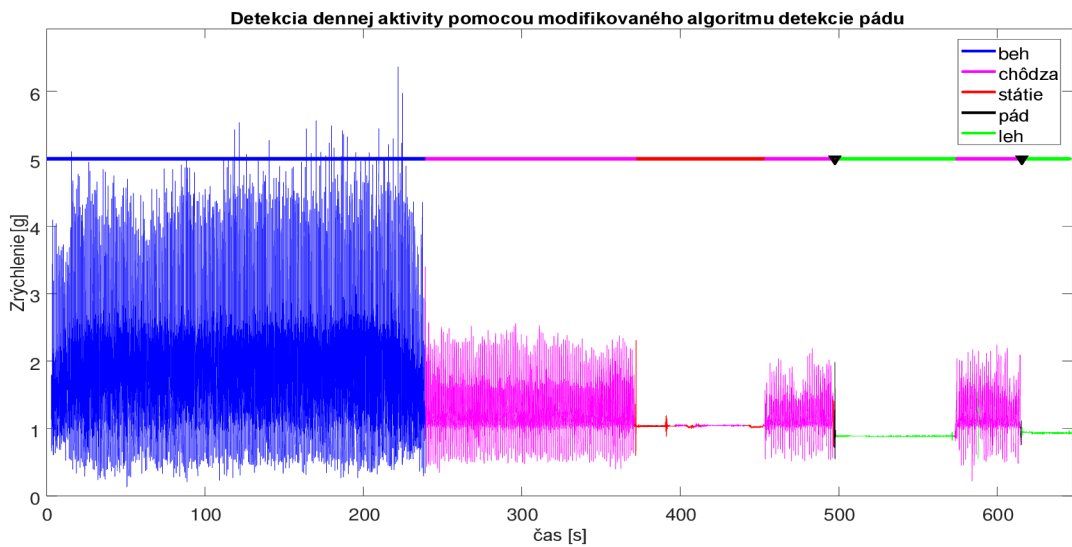
Pomocou tohto algoritmu je možné hodnotiť nasledujúce aktivity: beh, chôdza, státie, ležanie a pád. Tabuľka číslo 5.1 nám zobrazuje odhad chýb a presnosť výsledku detekcie pre signál popísaný v kapitole 3.2. Presnosť detekcie ktorá je vypočítaná ako presná detekcia (100 % správnosť) mínus odhad chyby.

Tabuľka 5.1 Odhad chýb pre konkrétny typ aktivity a presnosť detekcie (algoritmus detekcie pádu)

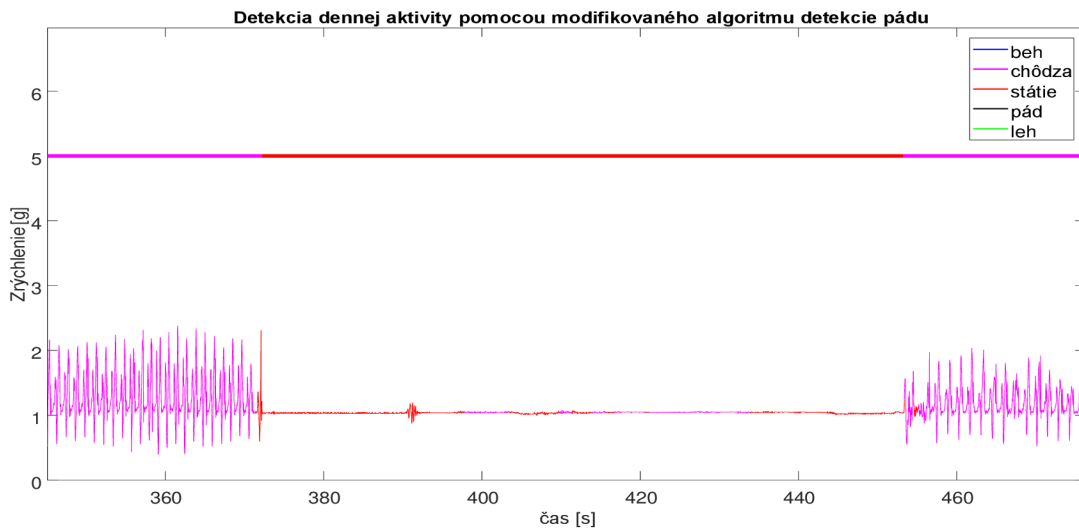
Aktivita	Odhad chyby [%]	Presnosť [%]
Beh	0,02	99,98
Chôdza	1,25	98,75
Státie	46,10	53,90
Ležanie	1,33	98,67
Pád	0,00	100,00

Prípadné nepresnosti môžu byť ovplyvnené výberom veľkosti okna a artefaktmi vzniknutými pri snímaní.


Veľkosť okna bola na základe empirických znalostí zvolená na hodnotu $ww = 15$ vzoriek čo odpovedá 0,3 sekundy pri $f_{vz} = 50$ Hz. Ako najväčšia nepresnosť sa pokladá nesprávna detekcia chôdze (magenta) na úseku státia (červená) (400-430 s). Táto nepresnosť (obrázok 5.2) je spôsobená artefaktmi na nasnímanom signále čo je viditeľné už na obrázku číslo 4.3, kedy sú hodnoty SMA v tomto úseku kmitajúce. Na obrázku 5.3 je zobrazený detail pre detekciu pádu. Výsledok detekcie pomocou tohto algoritmu je zobrazený na obrázku číslo 5.1.



Obrázok 5.1 Výsledok detekcie prostredníctvom modifikovaného algoritmu detekcie pádu



Obrázok 5.2 Detail nepresnosti detekcie



Obrázok 5.3 Detail detekcie pádu

5.2 Presnosť krokomerov

Pre spočítanie krokov a rozlíšenie fyzickej aktivity boli použité dve rôzne metódy. Výstupom oboch algoritmov je počet krokov, klasifikácia behu, chôdze a státia. Výsledky odhadov chýb klasifikácií a počtu krokov sú vyhodnotené v kapitolách 5.2.1 a 5.2.2.

5.2.1 Presnosť krokomeru 1

Výsledok klasifikácie aktivít signálu nasnímaného pre hodnotenie presnosti algoritmov krokomeru (signál je popísaný v kapitole 3.2) je vykreslený na obrázku číslo 5.4.


Hlavné faktory, ktoré môžu spôsobiť nepresnosti sú nekonštantná rýchlosť vo vykonávaní aktivity a veľkosť použitého okna pri detekcií. V tomto algoritme je použité okno o veľkosti 85 vzoriek, čo odpovedá 1,7 sekundám. Nepresnosti pri detekcií sú ovplyvnené rýchlosťou chôdze a behu, kedy chôdza alebo beh nie sú konštantné. Najväčšia nepresnosť detekcie sa vyskytuje pri zmene jednej aktivity na ďalšiu.

Algoritmus hodnotí aktivity na základe počtu krokov vykonaných v časovom úseku 1,7 sekundy. Pokiaľ je počet krokov v časovom úseku 2 sekúnd väčší pokladá sa aktivita za beh, pokiaľ je počet krokov menší ako 2 a zároveň väčšia ako 0,2 hodnotíme aktivitu ako chôdzu. Pokiaľ je hodnota počtu krokov v časovom úseku 1,7 sekundy blízka 0 predpokladá sa, že osoba je v kľude. V rámci snahy o vytvorenie presnejšieho algoritmu bola vyskúšaná aj zmenená podmienka a to z 2 krokov za 1,7 sekundy na 2 kroky za 2 sekundy. Pri tejto zmene podmienky však dochádzalo ku väčším nepresnostiam. Výsledok upravenej podmienky je zobrazený na obrázku 5.5. Výsledky chýb detekcií vypočítané podľa (12) sú zobrazené v tabuľke číslo 5.2.


Tabuľka 5.2 Odhad chýb pre konkrétny typ aktivity a presnosť detekcie (krokomer 1)

Aktivita	Algoritmus	Odhad chyby [%]	Presnosť [%]
Beh	2 kroky za 1,7 s	3,77	96,23
	2 kroky za 2 s	16,71	83,29
Chôdza	2 kroky za 1,7 s	3,91	96,09
	2 kroky za 2 s	0,39	99,61
Státie	2 kroky za 1,7 s	3,35	96,65
	2 kroky za 2 s	4,17	95,83
Kroky	-	2,50	97,50

V nasnímanom zázname bolo vykonaných 400 krokov. Algoritmus detekuje 410 krokov. Chyba tohto algoritmu (δ) vypočítaná pomocou (12) je 2,50%. Zároveň boli snímané kroky aj pomocou Fitbit Alta HR. Toto zariadenie nám nadetekovalo 485 krokov. Toto zariadenie sa však nepokladá za presné (vysvetlenie kapitola 3.1).



Obrázok 5.4 Výsledok detekcie prostredníctvom algoritmu krokomeru 1 (2 kroky za 1,7 s)



Obrázok 5.5 Výsledok detekcie prostredníctvom algoritmu krokomeru 1 (2 kroky za 2s)


5.2.2 Presnosť krokometru 2

Tento algoritmus detekuje počet krokov pre nohu, na ktorej je umiestnené snímacie zariadenie. Pre celkový počet krokov je potrebné túto hodnotu vynásobiť dvoma. Tabuľka 5.3 zobrazuje odhad chýb a presnosť pri detekcii prostredníctvom krokometru 2.

Tabuľka 5.3 Odhad chýb pre konkrétny typ aktivity a presnosť detekcie (krokometru 2)

Aktivita	Odhad chyby [%]	Presnosť [%]
Beh	0,96	99,04
Chôdza	0,01	99,99
Státie	1,44	98,56
Kroky	4,00	96,00

Najväčšia nepresnosť je pri detekcii počtu krokov, kedy sa nám hodnota odhadu chyby rovná až 4 %. Táto nepresnosť môže byť ovplyvnená nepresnosťou pri snímaní alebo faktom, že pri umocnení signálu nedošlo ku úplnému potlačeniu kroku druhej nohy. Presnosť všetkých aktivít je v rozsahu 95-100 %. Obrázok číslo 5.6 zobrazuje výsledok hodnotenia aktivity (chôdza, beh) pomocou krokometru 2. Nepresnosti ostatných aktivít sú hlavne pri prechode z jednej aktivity na druhú. Táto nepresnosť sa dá ovplyvniť výberom okna w . Obrázok číslo 5.6 zobrazuje výsledok hodnotenia aktivity pomocou krokometru 2.



Obrázok 5.6 Výsledok hodnotenia aktivity prostredníctvom krokometru 2

6 POROVNANIE PRESNOSTI ROZPOZNANIA AKTIVÍT A DETEKCIA KROKOV POMOCOU CHYTRÉHO TELEFÓNU A NÁRAMKU AXIVITY AX3

V tejto kapitole sa nachádzajú tabuľky presností pre jednotlivé testovacie signály. Počet testovacích signálov je 60. Výber aktivít, ktoré boli vykonávané v nasnímaných signáloch bol prispôsobený algoritmu, ktorým boli vyhodnotené. Prvá polovica signálov (1 až 30 signál) je určená pre hodnotenie aktivít rozšíreným algoritmom detekcie pádu, druhá polovica signálov (31 až 60 signál) je určená pre algoritmy krokomer 1 a 2. Z tohto dôvodu v druhej polovici signálov neboli vykonávané aktivity ako je pád a ľah. Testovali sa tri vzorkovacie frekvencie 25, 50 a 100 Hz s umiestnením na biceps a nohe (členok / lýtkový sval). Testovalo sa zariadenie Axivity AX3 a dve aplikácie pre chytrý telefón - Sense it, Accelerometer analyzer. Aplikácia Acc. analyzer neumožňuje snímať s vzorkovacou frekvenciou 25 Hz, preto v prípade tejto aplikácie boli testované len vzorkovacie frekvencie 50 a 100 Hz. Každá kombinácia bola nasnímaná nezávisle trikrát pre spoľahlivejšie určenie presnosti. Tieto tri nezávislé signály o rovnakých podmienkach snímania vytvárajú pomyselný set teda jednu tabuľku. Signály boli snímané 2 osobami.

6.1 Rozšírený algoritmus detekcie pádu

Výpočet presností je rovnako ako testovanie presnosti algoritmov (kapitola 5) realizovaný prostredníctvom vzorca (12). Týmto postupom sa určí presnosť všetkých aktivít s výnimkou pádu. Hodnotenie presnosti pádu je vykonávané prostredníctvom podmienky: pokiaľ sa pád detekuje (neberie sa ohľad na počet vzoriek) a pád sa naozaj uskutočnil hodnotí sa presnosť pádu ako 100 %. Pokiaľ osoba padla avšak algoritmus nerozoznal aktivitu, presnosť detekcie pádu je nulová. Presnosť 50 % teda znamená, že algoritmus bol schopný rozpoznať iba polovicu skutočne vykonaných pádov. V 82,67 % prípadoch z prvej polovice nasnímaných signálov (1-30 signál) sa presnosť detekcie aktivít nachádza v rozmedzí od 90 do 100 %.

6.1.1 Sense it x Axivity AX3

Tabuľka 6.1 Presnosť pre rozšírený algoritmus detekcie pádu (50 Hz, noha a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]				
		Beh	Chôdza	Státie	Ležanie	Pád
1	Axivity AX3	97,18	93,51	98,38	89,32	100,00
	Chytrý telefón	96,85	93,51	96,57	86,55	100,00
2	Axivity AX3	97,47	99,24	97,70	98,80	50,00
	Chytrý telefón	97,86	99,66	97,74	97,29	100,00
3	Axivity AX3	93,84	90,52	99,56	99,60	100,00
	Chytrý telefón	96,23	40,43	97,98	94,59	50,00

Tabuľka 6.2 Presnosť pre rozšírený algoritmus detekcie pádu (100 Hz, noha a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]				
		Beh	Chôdza	Státie	Ležanie	Pád
4	Axivity AX3	97,40	95,26	99,97	99,63	100,00
	Chytrý telefón	90,89	99,96	99,67	97,52	100,00
5	Axivity AX3	100,00	99,28	99,97	99,76	100,00
	Chytrý telefón	99,48	99,01	99,64	97,31	100,00
6	Axivity AX3	99,92	97,95	98,27	99,26	100,00
	Chytrý telefón	97,40	99,22	98,92	99,50	100,00

Tabuľka 6.3 Presnosť pre rozšírený algoritmus detekcie pádu (25 Hz, noha a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]				
		Beh	Chôdza	Státie	Ležanie	Pád
7	Axivity AX3	99,76	97,67	99,93	95,90	100,00
	Chytrý telefón	99,66	97,54	99,89	95,30	100,00
8	Axivity AX3	97,85	98,69	100,00	98,27	100,00
	Chytrý telefón	96,76	98,25	100,00	98,78	100,00
9	Axivity AX3	99,74	98,82	98,77	93,05	100,00
	Chytrý telefón	99,74	99,01	98,23	92,04	100,00

Tabuľka 6.4 Presnosť pre rozšírený algoritmus detekcie pádu (50 Hz, biceps a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]				
		Beh	Chôdza	Státie	Ležanie	Pád
10	Axivity AX3	96,30	99,87	98,62	0,00	0,00
	Chytrý telefón	96,57	98,05	67,08	0,00	0,00
11	Axivity AX3	99,85	75,33	94,34	90,19	100,00
	Chytrý telefón	99,93	98,13	72,39	0,00	0,00
12	Axivity AX3	91,15	98,27	99,45	91,15	100,00
	Chytrý telefón	97,94	97,24	28,15	41,52	100,00

Tabuľka 6.5 Presnosť pre rozšírený algoritmus detekcie pádu (100 Hz, biceps a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]				
		Beh	Chôdza	Státie	Ležanie	Pád
13	Axivity AX3	95,03	91,30	95,75	0,00	0,00
	Chytrý telefón	96,02	99,34	95,13	0,00	0,00
14	Axivity AX3	95,49	81,87	99,21	90,61	100,00
	Chytrý telefón	95,98	95,33	48,00	90,33	100,00
15	Axivity AX3	97,29	6,61	99,93	95,93	100,00
	Chytrý telefón	3,26	74,66	100,00	94,32	100,00

Tabuľka 6.6 Presnosť pre rozšírený algoritmus detekcie pádu (25 Hz, biceps a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]				
		Beh	Chôdza	Státie	Ležanie	Pád
16	Axivity AX3	91,89	5,85	100,00	96,95	100,00
	Chytrý telefón	96,32	96,19	96,70	76,11	100,00
17	Axivity AX3	92,71	11,63	99,80	88,86	100,00
	Chytrý telefón	96,52	93,71	21,71	90,29	100,00
18	Axivity AX3	88,42	76,21	99,78	93,10	100,00
	Chytrý telefón	94,59	96,05	29,43	90,62	100,00

6.1.2 Accelerometer analyzer x Axivity AX3

Tabuľka 6.7 Presnosť pre rozšírený algoritmus detekcie pádu (50 Hz, noha a Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]				
		Beh	Chôdza	Státie	Ležanie	Pád
19	Axivity AX3	93,86	99,49	99,38	98,61	100,00
	Chytrý telefón	93,72	98,15	99,53	97,22	100,00
20	Axivity AX3	95,13	91,80	99,08	95,36	100,00
	Chytrý telefón	94,94	99,63	97,89	95,15	100,00
21	Axivity AX3	96,15	99,76	98,97	98,94	100,00
	Chytrý telefón	97,95	99,44	99,72	93,05	100,00

Tabuľka 6.8 Presnosť pre rozšírený algoritmus detekcie pádu (100 Hz, noha a Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]				
		Beh	Chôdza	Státie	Ležanie	Pád
22	Axivity AX3	94,77	99,54	99,23	98,98	100,00
	Chytrý telefón	94,68	98,38	99,00	98,14	100,00
23	Axivity AX3	98,11	92,28	98,74	99,85	100,00
	Chytrý telefón	97,09	88,24	98,85	99,00	100,00
24	Axivity AX3	99,03	95,27	99,70	99,22	100,00
	Chytrý telefón	98,39	93,63	99,09	98,11	100,00

Tabuľka 6.9 Presnosť pre rozšírený algoritmus detekcie pádu (50 Hz, biceps a Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]				
		Beh	Chôdza	Státie	Ležanie	Pád
25	Axivity AX3	91,55	2,24	95,63	69,64	100,00
	Chytrý telefón	96,04	97,92	92,13	74,73	100,00
26	Axivity AX3	95,01	73,20	92,63	87,97	100,00
	Chytrý telefón	96,09	98,75	87,36	86,50	100,00
27	Axivity AX3	91,98	92,77	43,29	89,86	100,00
	Chytrý telefón	89,71	94,83	42,67	15,58	100,00

Tabuľka 6.10 Presnosť pre rozšírený algoritmus detekcie pádu (100 Hz, biceps a Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]				
		Beh	Chôdza	Státie	Ležanie	Pád
28	Axivity AX3	99,08	96,76	97,07	84,81	100,00
	Chytrý telefón	99,94	95,89	51,50	52,58	50,00
29	Axivity AX3	96,11	98,93	96,16	64,10	100,00
	Chytrý telefón	96,55	98,03	3,24	94,03	100,00
30	Axivity AX3	97,45	99,45	45,22	88,40	100,00
	Chytrý telefón	99,84	98,26	0,00	57,57	100,00

6.2 Krokomer 1

Úspešnosť detekcie je hodnotená rovnako ako testovanie presnosti algoritmov (kapitola 5) realizovaný prostredníctvom vzorca (12). Pre algoritmus krokomeru boli vytvorené samostatné sety signálov. Algoritmy krokomerov by nemali vyhodnocovať sety signálov určené pre rozšírený algoritmus detekcie pádu z dôvodu neschopnosti detekovať aktivity ako je pád a ľah. Algoritmus by ľah klasifikoval ako státie čo by bola nesprávna detekcia.

Presnosť stanovenia počtu krokov je závislá hlavne na umiestnení zariadenia. Algoritmus krokomeru 1 má tendenciu počet krokov podhodnocovať. Podhodnotenie krokov je ešte intenzívnejšie pri umiestnení na bicepse kedy zrýchlenie nepresahuje prahovú hodnotu určenú v algoritme a krok sa nedetekuje. S využitím náramku Axivity AX3 bol výsledný počet krokov v 23 signáloch podhodnotený, v 4 signáloch bol nadhodnotený a len v 3 signáloch bolo stanovenie počtu krokov presné. V prípade snímania chytrým telefónom bol výsledný počet krokov v 18 signáloch podhodnotený, v 10 signáloch bol výsledný počet nadhodnotený a len v 2 signáloch sa podarilo počet krokov určiť presne. Z 300 hodnôt presnosti len 28 hodnôt je pod hranicou 90 % presnosti a teda presnosť detekcií sa v 90,67 % nachádza v rozmedzí 90 až 100 %.

6.2.1 Sense it x Axivity AX3

Tabuľka 6.11 Presnosť pre krokomer 1 (50 Hz, noha a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
31	Axivity AX3	99,93	99,30	99,00	98,89
	Chytrý telefón	98,66	99,90	99,40	98,33
32	Axivity AX3	99,34	98,68	97,93	99,60
	Chytrý telefón	92,37	99,73	99,34	99,60
33	Axivity AX3	99,27	98,47	97,73	96,00
	Chytrý telefón	98,03	100,00	96,40	99,43

Tabuľka 6.12 Presnosť pre krokomer 1 (100 Hz, noha a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
34	Axivity AX3	98,60	97,34	98,18	99,00
	Chytrý telefón	95,72	98,55	97,80	99,50
35	Axivity AX3	96,68	99,17	98,77	100,00
	Chytrý telefón	86,16	100,00	98,93	98,93
36	Axivity AX3	99,68	99,77	99,31	99,50
	Chytrý telefón	99,25	99,64	98,94	99,00

Tabuľka 6.13 Presnosť pre krokomer 1 (25 Hz, noha a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
37	Axivity AX3	89,94	99,12	98,88	95,83
	Chytrý telefón	99,19	99,59	98,89	95,83
38	Axivity AX3	90,88	99,54	99,40	99,00
	Chytrý telefón	84,77	99,68	99,66	96,50
39	Axivity AX3	69,01	99,35	99,35	96,55
	Chytrý telefón	97,26	99,21	99,12	95,67

Tabuľka 6.14 Presnosť pre krokomer 1 (50 Hz, biceps a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
40	Axivity AX3	96,77	93,61	99,10	80,00
	Chytrý telefón	71,44	100,00	99,42	97,22
41	Axivity AX3	95,46	98,54	99,40	99,52
	Chytrý telefón	71,84	93,97	98,65	98,57
42	Axivity AX3	93,85	94,76	98,19	88,15
	Chytrý telefón	87,87	97,52	97,87	98,15

Tabuľka 6.15 Presnosť pre krokomer 1 (100 Hz, biceps a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
43	Axivity AX3	95,37	96,39	97,60	92,50
	Chytrý telefón	88,64	98,19	96,96	98,93
44	Axivity AX3	95,54	99,53	99,57	80,00
	Chytrý telefón	95,54	99,98	95,30	98,82
45	Axivity AX3	94,95	98,49	97,74	96,96
	Chytrý telefón	90,16	98,94	97,74	97,39

Tabuľka 6.16 Presnosť pre krokomer 1 (25 Hz, biceps a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
46	Axivity AX3	85,00	89,79	97,83	76,52
	Chytrý telefón	65,33	96,54	97,92	97,73
47	Axivity AX3	90,36	71,10	99,40	62,79
	Chytrý telefón	82,08	98,22	99,49	95,52
48	Axivity AX3	94,00	93,44	99,34	76,55
	Chytrý telefón	86,82	98,27	97,90	97,93

6.2.2 Accelerometer analyzer x Axivity AX3

Tabuľka 6.17 Presnosť pre krokomer 1 (50 Hz, noha, Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
49	Axivity AX3	94,85	98,94	97,69	99,00
	Chytrý telefón	98,18	99,50	97,99	100,00
50	Axivity AX3	94,70	98,88	98,68	99,50
	Chytrý telefón	96,37	99,28	98,72	99,75
51	Axivity AX3	96,01	98,92	98,49	100,00
	Chytrý telefón	98,76	99,90	98,97	99,67

Tabuľka 6.18 Presnosť pre krokomer 1 (100 Hz, noha a Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
52	Axivity AX3	96,23	99,64	97,88	99,00
	Chytrý telefón	96,22	99,38	97,51	61,00
53	Axivity AX3	99,07	99,62	98,33	88,57
	Chytrý telefón	96,22	99,39	99,00	99,52
54	Axivity AX3	98,80	99,69	96,06	100,00
	Chytrý telefón	95,23	97,83	98,81	86,67

Tabuľka 6.19 Presnosť pre krokomer 1 (50 Hz, biceps, Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
55	Axivity AX3	75,86	96,10	96,68	44,45
	Chytrý telefón	94,08	98,43	96,52	97,78
56	Axivity AX3	93,71	98,46	97,03	99,45
	Chytrý telefón	94,35	99,21	97,56	100,00
57	Axivity AX3	94,91	96,88	98,08	87,11
	Chytrý telefón	95,19	98,69	98,02	96,32

Tabuľka 6.20 Presnosť pre krokomer 1 (100 Hz, biceps a Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
58	Axivity AX3	91,96	65,31	98,41	67,50
	Chytrý telefón	92,83	98,02	98,93	98,00
59	Axivity AX3	96,50	94,82	99,23	81,20
	Chytrý telefón	96,96	99,78	99,47	98,00
60	Axivity AX3	96,67	94,44	99,63	77,86
	Chytrý telefón	96,70	99,37	99,53	93,81

6.3 Krokomer 2

Krokomerom 2 boli hodnotené rovnaké sety signálov ako pri algoritme krokomeru 1.

Zatiaľ čo algoritmus krokomeru 1 má tendenciu kroky podhodnocovať algoritmus krokomeru 2 využívajúci EMD má tendenciu kroky aj nadhodnocovať aj podhodnocovať, závisí to od typu použitého snímacieho zariadenia. V prípade snímania náramkom Axivity AX3 dochádza ku podhodnoteniu krokov až v 23 signáloch, len v 3 signáloch kroky nadhodnocuje. Snímanie chytrým telefónom naopak podhodnotilo počet krokov v 12 signáloch a v 17 signáloch kroky nadhodnotilo. Tento algoritmus vykazuje najviac hodnôt presnosti v rozmedzí od 90 – 100 %. Percentuálne zastúpenie hodnôt v spomínanom rozmedzí je 94,67 %. Detailnejšie porovnanie presnosti algoritmov medzi sebou je popísané v kapitole 7.2.

6.3.1 Sense it x Axivity AX3

Tabuľka 6.21 Presnosť pre krokomer 2 (50 Hz, noha a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
31	Axivity AX3	99,67	99,86	99,70	97,78
	Chytrý telefón	99,65	97,18	99,61	98,33
32	Axivity AX3	99,77	99,06	99,08	99,20
	Chytrý telefón	99,67	99,37	99,71	97,20
33	Axivity AX3	99,29	98,17	98,79	100,00
	Chytrý telefón	98,76	98,22	99,77	99,43

Tabuľka 6.22 Presnosť pre krokomer 2 (100 Hz, noha a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
34	Axivity AX3	99,59	99,57	98,82	99,00
	Chytrý telefón	99,89	90,94	98,68	94,40
35	Axivity AX3	98,66	99,18	98,94	99,29
	Chytrý telefón	43,35	95,30	99,79	95,00
36	Axivity AX3	99,97	91,67	99,50	95,00
	Chytrý telefón	99,41	91,72	99,25	98,00

Tabuľka 6.23 Presnosť pre krokomer 2 (25 Hz, noha a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
37	Axivity AX3	98,86	99,77	99,36	97,50
	Chytrý telefón	99,92	99,91	99,75	97,50
38	Axivity AX3	99,21	99,67	99,87	97,00
	Chytrý telefón	98,55	99,94	99,78	98,00
39	Axivity AX3	90,25	99,97	99,73	94,00
	Chytrý telefón	98,37	99,09	99,61	93,33

Tabuľka 6.24 Presnosť pre krokomer 2 (50 Hz, biceps a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
40	Axivity AX3	96,77	93,61	99,10	80,00
	Chytrý telefón	71,44	100,00	99,42	97,22
41	Axivity AX3	96,80	98,62	99,97	96,19
	Chytrý telefón	98,21	92,47	99,97	99,05
42	Axivity AX3	94,76	99,21	99,69	91,85
	Chytrý telefón	99,68	99,44	99,89	98,52

Tabuľka 6.25 Presnosť pre krokomer 2 (100 Hz, biceps a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
43	Axivity AX3	99,60	97,07	99,90	98,57
	Chytrý telefón	99,35	7,02	99,06	48,57
44	Axivity AX3	99,66	98,83	95,30	98,82
	Chytrý telefón	99,53	98,50	98,66	98,82
45	Axivity AX3	99,91	98,49	99,65	96,52
	Chytrý telefón	99,53	98,70	99,71	96,52

Tabuľka 6.26 Presnosť pre krokomer 2 (25 Hz, biceps a Sense it)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
46	Axivity AX3	98,12	95,88	99,88	92,42
	Chytrý telefón	99,00	86,48	99,94	91,67
47	Axivity AX3	98,94	0,00	99,94	37,93
	Chytrý telefón	99,93	0,00	99,94	42,07
48	Axivity AX3	99,48	87,47	99,81	82,76
	Chytrý telefón	99,11	88,51	99,96	91,03

6.3.2 Accelerometer analyzer x Axivity AX3

Tabuľka 6.27 Presnosť pre krokomer 2 (50 Hz, noha, Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
49	Axivity AX3	99,65	99,37	99,27	100,00
	Chytrý telefón	99,15	99,88	98,81	97,00
50	Axivity AX3	99,83	99,90	99,75	99,00
	Chytrý telefón	98,12	98,71	99,61	97,50
51	Axivity AX3	99,85	98,69	99,28	99,33
	Chytrý telefón	99,74	96,75	99,49	96,67

Tabuľka 6.28 Presnosť pre krokomer 2 (100 Hz, noha, Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
52	Axivity AX3	99,96	99,70	99,39	100,00
	Chytrý telefón	98,39	95,14	99,11	84,00
53	Axivity AX3	99,96	99,35	99,37	97,14
	Chytrý telefón	99,80	99,78	99,31	95,24
54	Axivity AX3	99,89	99,79	99,89	86,67
	Chytrý telefón	98,35	98,56	99,28	80,00

Tabuľka 6.29 Presnosť pre krokomer 2 (50 Hz, biceps, Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
55	Axivity AX3	74,40	98,55	97,58	44,44
	Chytrý telefón	99,54	98,56	97,11	98,89
56	Axivity AX3	99,05	97,83	99,89	90,00
	Chytrý telefón	99,82	100,00	98,25	100,00
57	Axivity AX3	99,78	98,26	99,87	97,37
	Chytrý telefón	99,70	97,32	99,32	96,32

Tabuľka 6.30 Presnosť pre krokomer 2 (100 Hz, biceps, Accelerometer Analyzer)

Signál	Zariadenie	Presnosť rozlíšenia aktivít [%]			
		Beh	Chôdza	Státie	Kroky
58	Axivity AX3	97,39	97,41	99,08	98,00
	Chytrý telefón	99,20	98,09	100,00	98,00
59	Axivity AX3	99,98	99,35	100,00	100,00
	Chytrý telefón	99,66	99,28	100,00	96,00
60	Axivity AX3	99,76	99,01	100,00	94,29
	Chytrý telefón	99,75	98,68	99,91	99,52

7 VYHODNOTENIE ÚSPEŠNOSTI DETEKČIE

Cieľom tejto práce je porovnanie zariadení s rôznymi nastaveniami, ktoré umožňujú rozlíšiť aktivitu popri prípade spočítať kroky. Nasnímané signály a ich presnosť pomocou vytvorených algoritmov slúžia ako nástroj pre potrebné porovnanie. Na základe nasnímaných a vyhodnotených signálov existuje veľký počet variant hodnotení. Závisí aký parameter snímania chceme vyhodnotiť.

V prípade hodnotenia vzorkovacej frekvencie vieme spraviť priemer všetkých nasnímaných signálov pre každú vzorkovaciu frekvenciu a určiť tú, ktorá bude schopná najpresnejšie detekovať aktivity. Podobná analýza sa môže vykonať aj pre umiestnenie zariadenia, kde sa musí brať do úvahy vedomosť o ideálnych miestach pre snímanie jednotlivých aktivít. Pre detekciu viacerých aktivít je potrebné zvoliť umiestnenie pomocou kompromisu (menšia presnosť, ale viacero aktivít, alebo väčšia presnosť a menej aktivít). Podobným spôsobom sa môže analyzovať aj výber zariadenia, popri prípade výber aplikácie. Vzhľadom na to, že všetky tri faktory snímania sa navzájom ovplyvňujú nie sú v tejto práci vyhodnotené samostatne, ale vo vzájomnej závislosti. Zvýraznené polia v tabuľkách žltou farbou zobrazujú najvyššiu presnosť danej kombinácie.

7.1 Úspešnosť detekcie v závislosti na vzorkovacej frekvencií a mieste snímania

Tabuľka 7.1 zobrazuje presnosť pre jednotlivé tabuľky. Každá tabuľka zobrazená v kapitole 6 reprezentuje jeden set kombinácie vzorkovacej frekvencie a umiestnenia zariadenia. Pre jednu kombinácia boli nasnímané dva sety a to z dôvodu prispôsobenia vykonávaných aktivít algoritmom, jeden set pre rozšírený algoritmus detekcie pádu a druhý set pre krokmer 1 a 2. V prípade zariadenia Axivity AX3 bola daná kombinácia nasnímaná dvakrát a to z dôvodu porovnania s dvoma aplikáciami. Preto hodnota priemeru pre Axivity AX3 zobrazená v tabuľke 7.1 je vytvorená z 6tich záznamov zatiaľ čo hodnota pre aplikácie iba z troch záznamov. Aplikácia Accelerometer analyzer neposkytuje snímanie so vzorkovacou frekvenciou 25 Hz a preto sa presnosť nemôže určiť. Úlohou tejto práce je porovnať chytrý telefón a zariadenie Axivity AX3 preto zo vzniknutej tabuľky 7.1 bola vytvorená tabuľka 7.2, ktorá zobrazuje presnosť detekcie zariadení v závislosti na umiestnení a vzorkovacej frekvencií. Na základe tejto tabuľky je zostrojený obrázok 7.1.


Najpresnejšia kombinácia vyšla vzorkovacia frekvencia 100 Hz s umiestnením Axivity AX3 na členku. Druhá najlepšia kombinácia, ktorá vychádza len o 0,41% horšie je kombinácia chytrého telefónu s umiestnením na nohe a so vzorkovacou frekvenciou 25 Hz. Avšak keď zmeníme umiestnenie chytrého telefónu na biceps dostávame kombináciu s najmenšou presnosťou. Hodnoty úspešnosti detekcie s umiestnením na biceps sú takmer o 10 % nižšie ako presnosti s umiestnením na nohe.

Tabuľka 7.1 Presnosť pre jednotlivé tabuľky

Tabuľka	Miesto snímania	F _{vz} [Hz]	Presnosť [%]		
			Sense it	Accelerometer analyzer	Axivity AX3
1, 7	noha	50	89,68	97,76	95,72
2, 8		100	98,57	97,51	98,71
3		25	98,35	-	91,98
4, 9	biceps	50	59,80	84,82	82,01
5, 10		100	72,82	73,16	83,75
6		25	85,22	-	83,01
11, 17	noha	50	98,43	98,92	98,33
12, 18		100	97,70	93,90	98,29
13		25	97,11	-	94,74
14, 19	biceps	50	92,71	97,18	92,34
15, 20		100	96,38	97,62	92,01
16		25	92,81	-	86,34
21, 27	noha	50	98,91	98,45	99,35
22, 28		100	92,14	95,58	98,35
23		25	98,65	-	97,93
24, 29	biceps	50	96,28	98,74	93,48
25, 30		100	87,00	99,01	98,61
26		25	83,14	-	82,72

Tabuľka 7.2 Presnosť detekcie pre zariadenia v závislosti na umiestnení a vzorkovacej frekvencii

Umiestnenie zariadenia	F _{vz} [Hz]	Chytrý telefón	Axivity AX3
noha	25	98,04	94,88
	50	97,03	97,80
	100	95,90	98,45
biceps	25	87,06	84,03
	50	88,25	89,28
	100	87,67	91,46




Obrázok 7.1 Graf závislosti presnosti zariadení na f_{vz} a umiestnenia zariadení

7.2 Presnosť jednotlivých algoritmov

V tejto bakalárskej práci boli navrhnuté tri algoritmy, pričom všetky boli testované na 30 testovacích signáloch. Tabuľka 7.3 zobrazuje priemer úspešnosti detekcií aktivít týmito algoritmi. Najpresnejší algoritmus pre detekciu prostredníctvom chytrého telefónu je krokomer 1, ktorého presnosť dosahuje 96,28 %. Pri využití Axivity AX3 je najpresnejší krokomer 2, ktorého presnosť je len o 0,24 % menšia ako presnosť pre chytrý telefón a krokomer 1. Rozšírený algoritmus detekcie pádu má najnižšiu hodnotu presnosti, ale na oplátku poskytuje detekciu najväčšieho počtu aktivít. V prípade výberu rozšíreného algoritmu detekcie pádu a krokomeru 2 je presnejšia klasifikácia aktivít pomocou Axivity AX3, zatiaľ čo pri krokomeri 1 je výhodnejšie použiť chytrý telefón. Obrázok 7.2 je grafickým zobrazením tabuľky 7.3.

Tabuľka 7.3 Úspešnosť detekcie pre algoritmy

Algoritmus	Chytrý telefón	Axivity AX3
1	85,77	90,14
2	96,28	94,34
3	94,79	96,02



Obrázok 7.2 Graf závislosti presnosti zariadení na voľbe algoritmoch

7.3 Štatistické zhodnotenie kvality použitých zariadení

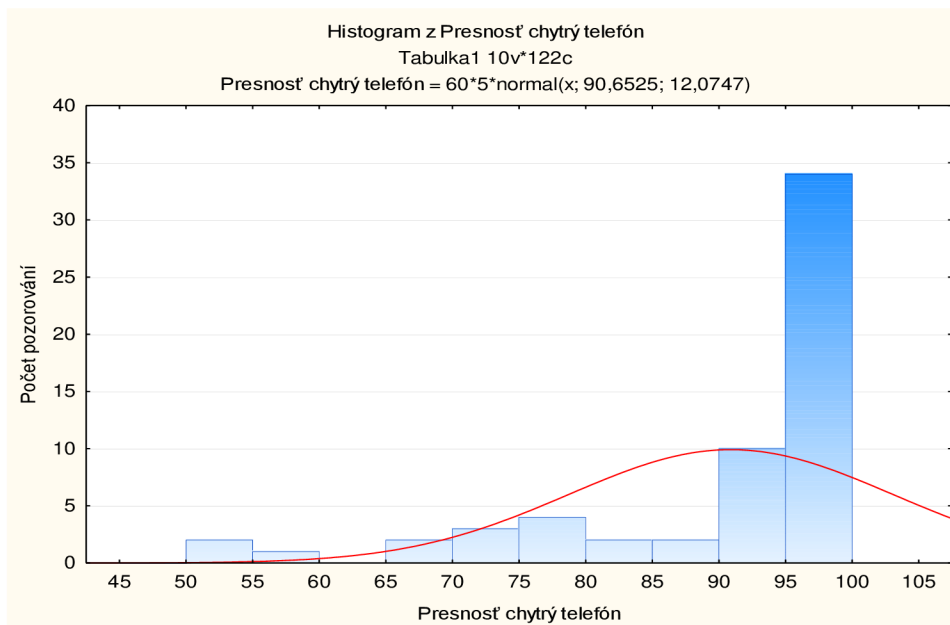
Tabuľka 7.4 zobrazuje úspešnosť detekcie pre jednotlivé záznamy. Pri testovaní rozloženia dát z chytrého telefónu (obrázok 7.3) a z Axivity AX3 (obrázok 7.4) sa normálne ani log-normálne rozloženie dát nepotvrdilo. Párový t-test sa aplikuje na dáta s normálnym rozložením a preto sa využíva jeho neparametrická alternatíva Wilcoxonov párový test [36]. Pred použitím Wilcoxonovho testu sa stavia H_0 (nulová) a H_A (alternatívna) hypotéza.

Tabuľka 7.4 Úspešnosť detekcie pre jednotlivé záznamy

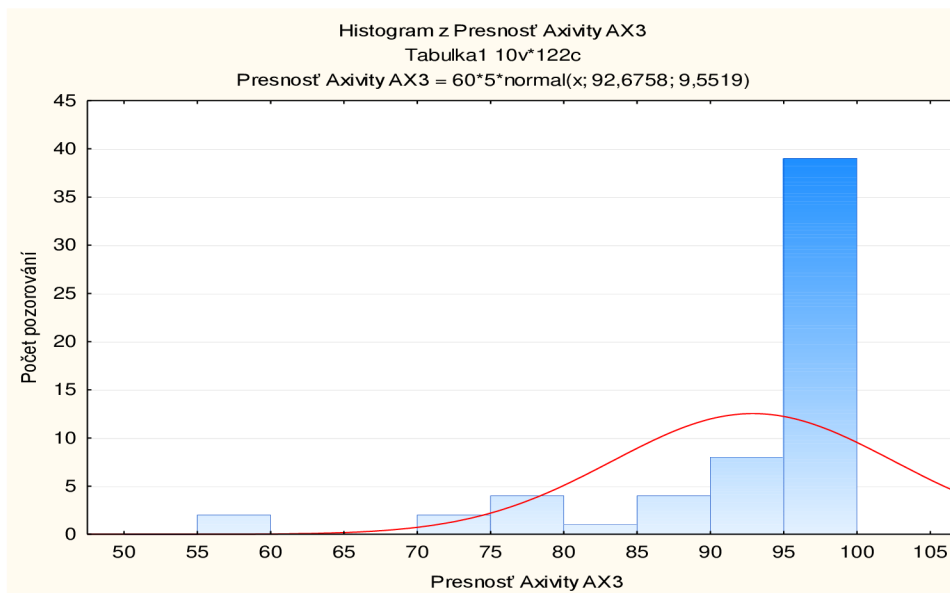
Signál	Presnosť [%]		Signál	Presnosť [%]	
	Chytrý telefón	Axivity AX3		Chytrý telefón	Axivity AX3
1	94,70	95,68	31	98,88	99,27
2	98,51	88,64	32	98,37	99,08
3	75,85	96,70	33	98,76	98,47
4	97,61	98,45	34	96,94	98,76
5	99,09	99,80	35	89,68	98,84
6	99,01	99,08	36	98,15	98,05
7	98,48	98,65	37	98,82	97,41
8	98,76	98,96	38	97,11	98,07
9	97,80	97,89	39	97,71	93,53
10	52,34	58,96	40	92,02	92,37
11	54,09	91,94	41	94,09	98,06
12	72,97	96,00	42	97,37	95,06
13	58,10	56,42	43	79,59	97,13
14	85,93	93,44	44	98,14	95,91
15	74,45	79,95	45	97,34	97,84
16	93,06	78,94	46	91,83	91,93
17	80,45	78,60	47	77,16	70,06
18	82,14	91,50	48	94,94	91,61
19	97,72	98,27	49	98,92	98,60
20	97,52	96,27	50	98,51	98,78
21	98,03	98,76	51	98,74	98,82
22	98,04	98,50	52	91,34	98,98
23	96,64	97,80	53	98,53	97,68
24	97,84	98,64	54	94,34	97,60
25	92,16	71,81	55	97,61	78,51
26	93,74	89,76	56	98,65	96,93
27	68,56	83,58	57	97,61	96,53
28	69,98	95,54	58	97,88	89,38
29	78,37	91,06	59	98,64	96,39
30	71,13	86,10	60	98,41	95,21

H_0 hypotéza – diferencia presnosti hodnôt Axivity AX3 a chytrého telefónu je nulová (není štatisticky významný rozdiel medzi obidvoma zariadeniami).

H_A hypotéza – diferencia presnosti hodnôt Axivity AX3 a chytrého telefónu nie je nulová (existuje rozdiel medzi obidvoma zariadeniami).



Obrázok 7.3 Rozloženie hodnôt pre chytrý telefón



Obrázok 7.4 Rozloženie hodnôt pre Axivity AX3

Hladina významnosti bola stanovená na hodnotu $\alpha = 0,05$. Pokiaľ p-hodnota prekročí hladinu významnosti, nulová hypotéza H_0 sa nezamieta. V prípade p-hodnoty nižšej ako je stanovená hladina významnosti sa zamieta H_0 a platí hypotéza H_A . Tabuľka 7.5 zobrazuje výsledok Wilcoxonovho párového testu, ktorý nám potvrdil fakt, že H_0 hypotézu nezamietame.

Tabuľka 7.5 Wilcoxonov párový test

Dvojica premenných	Počet záznamov	T	Z	p-hodnota
Axivity AX3 x Chytrý telefón	60	759,00	1,15	0,25

P-hodnota vyšla pomerne nízka a z tohto dôvodu bola otestovaná aj korelácia pre zistenie ako moc dáta medzi sebou korelujú resp. zistenie existencie vzťahu medzi dvoma veličinami. Tento vzťah sa prejavuje tak, že zmena jednej veličiny spôsobí zmenu druhej hodnoty veličiny. Výsledný korelačný koeficient kvantifikuje mieru vzťahu medzi dvoma veličinami v tomto prípade dvoma presnosťami. [36]

Výsledné presnosti nemajú normálne rozloženie a preto sa využíva neparametrická metóda korelačnej analýzy – Spearmanův korelačný koeficient. Korelačný koeficient r môže nadobúdať hodnoty v rozsahu $<-1, 1>$. Hodnota r je kladná v prípade keď vyššie hodnoty presnosti chytrého telefónu súvisia s vyššími hodnotami presnosti zariadenia Axivity AX3, naopak záporná hodnota r predstavuje závislosť nižších hodnôt presnosti chytrého telefónu s nižšími presnosťami Axivity AX3. [36]
Znovu sa stanoví H_0 a H_A .

H_0 – hodnoty presnosti zariadení sú nezávislé náhodné veličiny ($r=0$)

H_A – hodnoty presnosti zariadení nie sú nezávislé náhodné veličiny ($r \neq 0$)

Tabuľka 7.6 zobrazuje výsledok korelácie, hodnota korelačného koeficientu je nenulová a kladná preto sa zamietá H_0 a platí hypotéza H_A . Hodnota korelačného koeficientu je 0,63 čo môžeme interpretovať ako závislosť avšak zariadenia nie sú rovnako presné ani zameniteľné.

Tabuľka 7.6 Výsledok korelácie

Presnosť	Chytrý telefón	Axivity AX3
Chytrý telefón	1,00	0,63
Axivity AX3	0,63	1,00

7.4 Presnosť jednotlivých aktivít v algoritmoch


Táto podkapitola bola vytvorená pre zjednodušenie budúceho výberu algoritmu. V prípade využitia algoritmu je významná vedomosť o jeho presnosti pre konkrétnu aktivitu. Síce algoritmus krokomeru 2 má celkovú presnosť najvyššiu nemusí táto presnosť byť najvyššia aj pre konkrétnu aktivitu, ktorú bude potreba snímať.

Tabuľka číslo 7.7 zobrazuje úspešnosť detekcie aktivít pre rozšírený algoritmus detekcie pádu. S výnimkou chôdze všetky aktivity detekuje presnejšie zariadenia Axivity AX3. V prípade snímania prostredníctvom Axivity AX3 je najpresnejšie snímanie behu následne státia, pádu, ľahu a najmenej presná je detekcie chôdze. V prípade snímania chytrým telefónom sa toto poradie skrz-naskrz mení a najvyššiu presnosť detekujeme pri chôdzi. S o niečo nižšou presnosťou nasleduje beh, pád, státie a ľah. Tento algoritmus v porovnaní s ostatnými dvoma algoritmi nedetekuje najpresnejšie ani beh, ani chôdzu, ani státie, avšak ako jediný je schopný detekovať ľah

a následný pád. Z tabuľky číslo 7.7 bolo vytvorené grafické znázornenie presností, ktoré je zobrazené obrázkom 7.5.

Tabuľka 7.7 Úspešnosť detekcie aktivít pre algoritmus 1

Algoritmus 1	Presnosť rozlíšenia aktivít [%]				
	beh	chôdza	státie	ľah	pád
Axivity AX3	95,98	81,40	94,82	86,54	91,67
Chytrý telefón	93,56	94,55	77,27	76,79	86,67




Obrázok 7.5 Graf závislosti presnosti zariadení na konkrétnych aktivitách (algoritmus 1)

Tabuľka číslo 7.8 a obrázok 7.6 zobrazujú presnosť detekcie konkrétnych aktivít pre krokomer 1. Zatiaľ čo v prvom algoritme bola presnosť jednoznačne vyššia pri použití Axivity AX3 v tomto algoritme je presnosť zariadení pre konkrétne aktivity vyvážená. Pre Axivity AX3 je najvyššia presnosť pre detekciu behu a státia a pre chytrý telefón pre chôdzu a výpočet krokov. Presnosť aktivít snímaných prostredníctvom Axivity AX3 a využitím krokomeru 1 klesá v tomto poradí: státie, chôdza, beh a kroky. V prípade snímania chytrým telefónom je poradie: chôdza, státie, kroky a s najmenšou presnosťou beh. Krokomer 1 s využitím chytrého telefónu má zo všetkých algoritmov najvyššiu presnosť pre detekciu chôdze a následného výpočtu krokov, Axivity AX3 si najvyššiu presnosť chôdze zo všetkých algoritmov udržuje avšak pri počítaní krokov s Axivity AX3 je presnejší krokomer 2.

Tabuľka 7.8 Úspešnosť detekcie aktivít pre algoritmus 2

Algoritmus 2	Presnosť rozlíšenia aktivít [%]			
	beh	chôdza	státie	kroky
Axivity AX3	93,80	95,60	98,43	89,37
Chytrý telefón	91,41	98,89	98,36	96,45




Obrázok 7.6 Graf závislosti presnosti zariadení na konkrétnych aktivitách (algoritmus 2)

Presnosť jednotlivých aktivít v krokometri 2 zobrazuje tabuľka 7.9 a obrázok 7.7. Podobne ako v krokometri 1 presnosť zariadení je pomerne vyvážená. Axivity AX3 najpresnejšie detekuje beh a chôdzu a chytrý telefón státie a počet krokov. Zo všetkých vytvorených algoritmov je krokomer 2 najúspešnejší v detekcii behu a státia.

Tabuľka 7.9 Úspešnosť detekcie aktivít pre algoritmus 3

Algoritmus 3	Presnosť rozlíšenia aktivít [%]			
	beh	chôdza	státie	kroky
Axivity AX3	97,96	94,78	99,35	92,00
Chytrý telefón	96,49	90,78	99,42	92,46



Obrázok 7.7 Graf závislosti presnosti zariadení na konkrétnych aktivitách (algoritmus 3)

8 DISKUSIA

Porovnanie zariadení bolo vykonané na základe schopnosti zariadenia detekovať vykonávané aktivity. Úspešnosť detekcie aktivít prostredníctvom akcelerometrických dát je závislá na faktoroch snímania aktivít. Medzi faktory snímania sa pokladá voľba zariadenia, vzorkovacej frekvencie a umiestnenia.

V prípade voľby chytrého telefónu ako snímacieho zariadenia existuje široká škála výberu aplikácií. Tieto aplikácie môžeme rozdeliť do dvoch skupín a to: aplikácie s výstupom spracovaných dát a aplikácie s výstupom surových dát. Výhodou chytrého telefónu je jeho dostupnosť a fakt, že chytrý telefón vlastní omnoho väčšia časť populácie ako špecializované zariadenia. Veľkým plusom je aj ponuka obrovského množstva aplikácií, v ktorých je možné nastavovať parametre snímania a hlavne je možné hodnotiť aktivity bez ďalšej potreby algoritmu (aplikácie majú vlastné algoritmy a výpočty). Avšak primárnym využitím telefónu nie je snímanie aktivít a preto aj samotný chytrý telefón môže spôsobovať artefakty snímania. Príkladom je keď chytrý telefón počas snímania zaznamená prijímajúci hovor, správu, email alebo upozornenie a zavibruje. V prípade krátkej vibrácie (prijatie správy, emailu, ...) dochádza ku malým artefaktom, ktoré algoritmy dokážu odfiltrovať, pokiaľ by vibrácia pretrvávala dlhodobo dochádza ku falošnej detekcii aktivít. Riešením tejto nevýhody je nastavenie chytrého telefónu do režimu lietadla. Vtedy snímanie nebude ovplyvnené artefaktami, ktoré sú spôsobené vibráciami, ale na oplátku telefón nebude prijímať správy, telefonáty, ...

Snímanie prostredníctvom Axivity AX3 je síce presnejšie, avšak toto zariadenie vlastní veľmi málo osôb. Hlavnou nevýhodou je, že zariadenie samo o sebe neposkytuje hodnotenie aktivít, ale len surové dáta, ktoré je potrebné spracovať narozdiel od chytrého telefónu (vie poskytnúť aj spracované aj surové dáta). Výhodou naopak je jeho pohodlná nositeľnosť, veľkosť, nízka váha a výdrž batérie. Zaťiaľ čo batéria chytrého telefónu vydrží počas snímania niekoľko hodín, Axivity AX3 niekoľko dní. Axivity AX3 v porovnaní s chytrým telefónom ponúka väčší rozsah vzorkovacích frekvencií, chytrý telefón v rozsahu 1 – 100 Hz, Axivity AX3 až 6,25 – 3 200 Hz.

Vzhľadom na fakt, že všetky merané pohyby sú obsiahnuté vo frekvenciách pod 20 Hz [11] najpoužívanejšia vzorkovacia frekvencia je v rozmedzí 20 Hz až 50 Hz [12]. Umiestnenie snímacieho zariadenia musí byť kompromisom medzi presnosťou snímania aktivít a pohodlnou nositeľnosťou. Vrečko nohavíc je síce pohodlné pre nosenie snímacieho zariadenia avšak amplitúdy zrýchlenia pri tomto umiestnení nemusia byť dostatočné pre klasifikáciu aktivít. Naopak amplitúda zrýchlenia je dostatočná pre klasifikáciu aktivít pri umiestnení na lýtkovom svale avšak na druhej strane pri dlhodobom snímaní môže byť pre snímanú osobu nepríjemná.

Vytvorené algoritmy sú istým kompromisom medzi presnosťou a možnosťou snímať pomocou rôznych aplikácií a akcelerometru Axivity AX3. V prípade prispôbenia algoritmov pre snímanie konkrétnym snímacím zariadením bude dochádzať ku vyššej presnosti detekcie aktivít.

Na základe tejto práce bola určená ideálna kombinácia snímacieho zariadenia, umiestnenia a vzorkovacej frekvencie pre každý algoritmus. V prípade rozšíreného algoritmu detekcie pádu je síce zariadenie Axivity AX3 presnejšie avšak rozdiel tejto presnosti nepresahuje 5 % a tak pre snímanie laickej verejnosti je dostačujúce aj snímanie prostredníctvom chytrého telefónu. V prípade výskumných štúdií je výhodnejšie použiť akcelerometer Axivity AX3. Presnosť krokomeru 1 vyšla vyššia o necelé 2 % pre chytrý telefón čo sa pokladá za obrovskú výhodu vzhľadom na pomer počtu vlastníkov chytrých telefónov a špecializovaných zariadení ako je Axivity AX3. V prípade krokomeru 2 vychádza síce presnosť Axivity AX3 vyššia, avšak len o necelé 1,5 % a preto sa chytrý telefón pokladá znovu za dostačujúci pre laické použitie.

Pri vzorkovacej frekvencii 25 Hz je rozdiel medzi umiestnením na biceps a na nohe takmer 11 % v prospech umiestnenia na nohe. V prípade vzorkovacích frekvencií 50 a 100 Hz je rozdiel o necelých 9 % taktiež v prospech umiestnenia na nohe.

Na základe vykonaného testovania sa javí ako najlepšia kombinácia zariadenia Axivity AX3 s umiestnením na členku a so vzorkovacou frekvenciou 100 Hz. Presnosť tejto kombinácie dosahuje 98,45 %.

Druhá najpresnejšia kombinácia je snímanie prostredníctvom chytrého telefónu s umiestnením na lýtkovom svale a so vzorkovacou frekvenciou 25 Hz. Táto kombinácia dosahuje len o 0,41 % nižšiu presnosť ako najlepšia kombinácia. Pre širokú verejnosť sa táto kombinácia pokladá za výhodnejšiu keďže na jednu domácnosť pripadá 0,98 telefónu. V prípade domácnosti tvorenej osobami v dôchodcovskom veku tento počet telefónov klesá na hodnotu 0,96. [1] Tieto štatistické údaje pochádzajú z roku 2014 a vzhľadom na rozvoj techniky sa predpokladá zvýšenie počtu chytrých telefónov v domácnostiach. Veľkou výhodou tejto kombinácie je aj nižšia vzorkovacia frekvencia, kedy pri dlhodobom snímaní dochádza ku výraznému šetreniu pamäti oproti snímaniu so vzorkovacou frekvenciou 100 Hz.

Pre komfortné snímanie dlhodobej aktivity a zároveň nezahlcovanie pamäti zariadenia je výhodné využitie tretej najpresnejšej kombinácie (členok, 50 Hz a Axivity AX3). Úspešnosť detekcie tejto kombinácie zaostáva od najpresnejšej kombinácie len o 0,65 %, preto v prípade dlhodobého snímania a menšej pamäte zariadenia sa pokladá táto kombinácia ako výhodnejšia voľba.

Výsledkom tejto práce je zistenie, že vyššia presnosť rozlíšenia aktivít je dosiahnutá prostredníctvom náramku Axivity AX3 a preto je toto zariadenie odporúčané pre výskumnú činnosť. Napriek tomu aj presnosť rozlíšenia aktivít prostredníctvom chytrého telefónu je dostatočne presná a preto je odporúčaná pre hodnotenie aktivity verejnosti. Zariadenie Fitbit Alta HR bolo otestované a jeho presnosť vychádzala 82,3 %, čo bolo oproti navrhnutým algoritmom markantný rozdiel. Toto zariadenie neklasifikuje aktivity a preto nebolo naďalej využívané. Fitbit Alta HR sa doporučuje pre snímania aktivít, kedy nie je potreba získať surové dáta a nie je potreba vysokej presnosti detekcie.

ZÁVER

Úlohou bakalárskej práce bolo porovnať zariadenia, ktorými sa sníma ľudská aktivita. V tejto práci boli popísané možnosti záznamu aktivít prostredníctvom troch typov zariadení: chytrých telefónov, fitness náramkov a zariadenia Axivity AX3. V kapitole 2 sú popísané ľudské aktivity, ktoré majú perspektívu pri hodnotení a časté aktivity človeka, ktoré sa dajú rozlíšiť pomocou snímacích zariadení, boli popísané vplyvy umiestnenia na nasnímaný signál a najčastejšie hodnoty vzorkovacích frekvencií.

V rámci praktickej časti sa nasníмали testovacie signály pomocou zariadení Axivity AX3 a chytrého telefónu, ktoré boli následne implementované na tri vytvorené algoritmy pre detekciu aktivity. Prvý algoritmus sa zameral na hodnotenie aktivít ako sú beh, ľah, chôdza, státie a hlavne na správnu detekciu pádu. Rozdelenie aktivity od kľudu bolo vykonané prostredníctvom výpočtu SMA. V prípade hodnoty vyššej ako je stanovený prah sa detekuje aktivita a tá sa následne rozdelí pomocou priemeru na chôdzu a beh. V prípade hodnoty nižšej ako je stanovený prah SMA sa rozdeľuje kľud na ľah a státie prostredníctvom výpočtu TA. V druhom algoritme ide o správnu detekciu počtu krokov a rozdelenie aktivít na základe počtu vykonaných krokov za istý časový úsek. Tretí algoritmus podobne ako druhý hodnotí aktivity: beh, chôdza, státie a dodatočný výpočet krokov. Pred samotnou klasifikáciou týchto aktivít je signál normalizovaný a nasleduje výpočet prahu pre konkrétne aktivity, ktorý je vykonaný prostredníctvom EMD metódy. Vypočíta sa obálka signálu, ktorá sa ešte umocní a tým je zvýraznené zrýchlenie nohy, na ktorej je umiestnené snímacie zariadenie. V stanovenom okne v umocnenej obálke sa porovná hodnota signálu a stanoveného prahu a na základe tohto porovnania sa klasifikuje aktivita. Po klasifikácii aktivít nasleduje výpočet krokov.

Pre porovnanie zariadení bolo nasnímaných 60 testovacích signálov s Axivity AX3 a chytrým telefónom. Tieto signály boli zaznamenané s rôznymi vzorkovacími frekvenciami a umiestneniami. Následne sa v testovacích signáloch klasifikovali aktivity pomocou navrhnutých algoritmov a vyhodnotila sa úspešnosť detekcie jednotlivých signálov. Hlavným krokom práce je porovnanie presnosti detekcií pre zariadenia (poprípade aplikácie), frekvencie, umiestnenia. Posledným krokom práce je odporúčenie výberu snímacieho zariadenia pre snímanie za rôznych podmienok.

LITERATURA

- [1] Výběrové šetření o informačních a komunikačních technologiích v domácnostech a jejich využívání jednotlivci (VŠIT). [online]. [cit. 2018-05-01]. Dostupné z: https://www.czso.cz/documents/10180/44822349/061004-16_B.pdf/c2edcfbc-f41f-472c-9bd0-616dbd29a5aa?version=1.1.
- [2] *Výsledky šetření o využívání informačních a komunikačních technologií v domácnostech a mezi jednotlivci* - 2004. 2004. Dostupné také z: https://www.czso.cz/csu/czso/9603-04-2004-ii_pouziti_mobilniho_telefonu_jednotlivci.
- [3] BASSETT , David R., Lindsay P. TOTH, Samuel R. LAMUNION a Scott E. CROUTER. Step Counting: A Review of Measurement Considerations and Health-Related Applications. *Sports Medicine* [online]. 2017, **47**(7), 1303-1315 [cit. 2018-05-22]. DOI: 10.1007/s40279-016-0663-1. ISSN 0112-1642. Dostupné z: <http://link.springer.com/10.1007/s40279-016-0663-1>.
- [4] GAVRIEL, Constantinos, Kim H. PARKER a A. Aldo FAISAL. Smartphone as an ultra-low cost medical tricorder for real-time cardiological measurements via ballistocardiography. In: 2015 IEEE 12th International Conference on Wearable and Implantable Body Sensor Networks (BSN) [online]. IEEE, 2015, 2015, s. 1-6 [cit. 2018-05-22]. DOI: 10.1109/BSN.2015.7299425. ISBN 978-1-4673-7201-5. Dostupné z: <http://ieeexplore.ieee.org/document/7299425/>.
- [5] MISRA, Aditi, Rohan BANERJEE, Anirban Dutta CHOUDHURY, Aniruddha SINHA a Arpan PAL. Novel peak detection to estimate HRV using smartphone audio. In: 2015 IEEE 12th International Conference on Wearable and Implantable Body Sensor Networks (BSN) [online]. IEEE, 2015, 2015, s. 1-6 [cit. 2018-05-22]. DOI: 10.1109/BSN.2015.7299378. ISBN 978-1-4673-7201-5. Dostupné z: <http://ieeexplore.ieee.org/document/7299378/>.
- [6] LAMONACA, Francesco, Domenico Luca CARNI, Domenico GRIMALDI, Alfonso NASTRO, Maria RICCIO a Vitaliano SPAGNOLO. Blood oxygen saturation measurement by smartphone camera. In: 2015 IEEE International Symposium on Medical Measurements and Applications (MeMeA) Proceedings [online]. IEEE, 2015, 2015, s. 359-364 [cit. 2018-05-22]. DOI: 10.1109/MeMeA.2015.7145228. ISBN 978-1-4799-6477-2. Dostupné z: <http://ieeexplore.ieee.org/document/7145228/>.
- [7] Fitbit [online]. [cit. 2018-05-17]. Dostupné z: <https://www.fitbit.com/eu/altahr>.

- [8] FENG, Yuanyuan, Christopher K. WONG, Vandana JANEJA, Ravi KUBER a Helena M. MENTIS. Comparison of tri-axial accelerometers step-count accuracy in slow walking conditions. *Gait & Posture* [online]. 2017, **53**, 11-16 [cit. 2018-05-22]. DOI: 10.1016/j.gaitpost.2016.12.014. ISSN 09666362. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0966636216307020>
- [9] Axivity [online]. [cit. 2018-05-17]. Dostupné z: <https://axivity.com/product/ax3>
- [10] HE, Y., Y. LI a S.-D. BAO. Fall Detection by Built-In Tri-Accelerometer of Smartphone. In: *International Conference on Biomedical and Health Informatics*. China: IEEE, 2012, s.184-187
- [11] KARANTONIS, D.M., M.R. NARAYANAN, M. MATHIE, N.H. LOVELL a B.G. CELLER. Implementation of a Real-Time Human Movement Classifier Using a Triaxial Accelerometer for Ambulatory Monitoring. *IEEE Transactions on Information Technology in Biomedicine* [online]. 2006, **10**(1), 156-167 [cit. 2018-05-22]. DOI: 10.1109/TITB.2005.856864. ISSN 1089-7771. Dostupné z: <http://ieeexplore.ieee.org/document/1573717/>
- [12] MORALES, Jafet a David AKOPIAN. Physical activity recognition by smartphones, a survey. *Biocybernetics and Biomedical Engineering*[online]. 2017, **37**(3), 388-400 [cit. 2018-05-22]. DOI: 10.1016/j.bbe.2017.04.004. ISSN 02085216. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S020852161630314X>
- [13] DEL ROSARIO, Michael, Stephen REDMOND a Nigel LOVELL. Tracking the Evolution of Smartphone Sensing for Monitoring Human Movement. *Sensors* [online]. 2015, **15**(8), 18901-18933 [cit. 2018-05-22]. DOI: 10.3390/s150818901. ISSN 1424-8220. Dostupné z: <http://www.mdpi.com/1424-8220/15/8/18901>
- [14] KHUSAINOV, Rinat, Djamel AZZI, Ifeyinwa ACHUMBA a Sebastian BERSCH. Real-Time Human Ambulation, Activity, and Physiological Monitoring: Taxonomy of Issues, Techniques, Applications, Challenges and Limitations. *Sensors* [online]. 2013, **13**(10), 12852-12902 [cit. 2018-05-22]. DOI: 10.3390/s131012852. ISSN 1424-8220. Dostupné z: <http://www.mdpi.com/1424-8220/13/10/12852>.

- [15] WARD, J.A., P. LUKOWICZ, G. TROSTER a T.E. STARNER. Activity Recognition of Assembly Tasks Using Body-Worn Microphones and Accelerometers. *IEEE Transactions on Pattern Analysis and Machine Intelligence* [online]. 2006, **28**(10), 1553-1567 [cit. 2018-05-22]. DOI: 10.1109/TPAMI.2006.197. ISSN 0162-8828. Dostupné z: <http://ieeexplore.ieee.org/document/1677514/>
- [16] KHAN, Adil Mehmood, Ali TUFAIL, Asad Masood KHATTAK a Teemu H. LAINE. Activity Recognition on Smartphones via Sensor-Fusion and KDA-Based SVMs. *International Journal of Distributed Sensor Networks* [online]. 2014, **10**(5), 503291- [cit. 2018-05-22]. DOI: 10.1155/2014/503291. ISSN 1550-1477. Dostupné z: <http://journals.sagepub.com/doi/10.1155/2014/503291>
- [17] MATHIE, Merryn J, Adelle C F COSTER, Nigel H. LOVELL, Branko G. CELLER, Stephen R LORD a Anne TIEDEMANN. A pilot study of long-term monitoring of human movements in the home using accelerometry. *Journal of Telemedicine and Telecare* [online]. 2016, **10**(3), 144-151 [cit. 2018-05-22]. DOI: 10.1258/135763304323070788. ISSN 1357-633X. Dostupné z: <http://journals.sagepub.com/doi/10.1258/135763304323070788>
- [18] HAN, Manhyung, La The VINH, Young-Koo LEE a Sungyoung LEE. Comprehensive Context Recognizer Based on Multimodal Sensors in a Smartphone. *Sensors* [online]. 2012, **12**(9), 12588-12605 [cit. 2018-05-22]. DOI: 10.3390/s120912588. ISSN 1424-8220. Dostupné z: <http://www.mdpi.com/1424-8220/12/9/12588>
- [19] Lifelog [online]. [cit. 2018-05-17]. Dostupné z: <https://www.sonymobile.com/cz/apps-services/lifelog/>
- [20] Lifelog [online]. [cit. 2018-05-17]. Dostupné z: <https://play.google.com/store/apps/details?id=com.sonymobile.lifelog&hl=sk>.
- [21] Step counter [online]. [cit. 2018-05-17]. Dostupné z: https://play.google.com/store/apps/details?id=pedometer.steptracker.calorieburner.stepcounter&hl=en_US.
- [22] Sense it [online]. [cit. 2018-05-17]. Dostupné z: <https://play.google.com/store/apps/details?id=org.greengin.sciencetoolkit&hl=en>
- [23] Lab4Physics [online]. [cit. 2018-05-17]. Dostupné z: <https://lab4u.co/lab4physics/>.

- [24] Sprakvue [online]. [cit. 2018-05-17]. Dostupné z: <https://www.pasco.com/sparkvue/>.
- [25] Accelerometer Analyzer [online]. [cit. 2018-05-17]. Dostupné z: https://play.google.com/store/apps/details?id=com.lul.accelerometer&hl=sk_
- [26] MATHIE, Merryn J. Monitoring and Interpreting Human Movement Patterns Using a Triaxial Accelerometer, dizertačná práca, Univ. New South Wales, Sydney, Australia, 2003
- [27] ZHENG, Y., W. K. WONG, X. GUAN a S. TROST. Physical Activity Recognition from Accelerometer Data Using a Multi-Scale Ensemble Method. Twenty-Seventh AAAI Conference on Artificial Intelligence [online]. Washington, 2013, 2(3), 1575-1581 [cit. 2017-05-17].
- [28] BAI, Jiawei, Chongzhi DI, Luo XIAO, Kelly R. EVENSON, Andrea Z. LACROIX, Ciprian M. CRAINICEANU, David M. BUCHNER a Jaroslaw HAREZLAK. An Activity Index for Raw Accelerometry Data and Its Comparison with Other Activity Metrics. PLOS ONE [online]. 2016, **11**(8), e0160644- [cit. 2018-05-22]. DOI: 10.1371/journal.pone.0160644. ISSN 1932-6203. Dostupné z: <http://dx.plos.org/10.1371/journal.pone.0160644>
- [29] FARKAS, Ioana a Elena DORAN. ACTIVITY RECOGNITION FROM ACCELERATION DATA COLLECTED WITH A TRI-AXIAL ACCELEROMETER. 2011, (52), 38-43. Dostupné také z: http://users.utcluj.ro/~ATN/papers/ATN_2_2011_6.pdf
- [30] RONZHINA, M. Umělá inteligence v medicíně (AUIN) [prezentácia]. [cit. 2018-05-17]
- [31] Counting Steps by Capturing Acceleration Data from Your Android [online]. [cit. 2018-05-17]. Dostupné z: <https://uk.mathworks.com/help/supportpkg/mobilesensor/examples/counting-steps-by-capturing-acceleration-data-from-your-android-device.html>
- [32] KOZUMPLÍK, J. Zpracování biologických signálů (AABS) [prezentácia]. [cit. 2018-05-17]

- [33] HUANG, N. E., Z. SHEN, S. R. LONG, a ďalší The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* [online]. 1998, **454**(1971), 903-995 [cit. 2018-05-23]. DOI: 10.1098/rspa.1998.0193. ISSN 1364-5021. Dostupné z: <http://rspa.royalsocietypublishing.org/cgi/doi/10.1098/rspa.1998.0193>
- [34] MŽOUREK, Z. Signal decomposition using EMD transformation. In *Proceedings of the 18th Conference STUDENT EEICT 2012*, 1, s. 46–48. VUT v Brně, Fakulta elektrotechniky a komunikačních technologií a Fakulta informačních technologií, 2012. ISBN 978-80-214-4460-7
- [35] KAČNÍKOVÁ, D.; NĚMCOVÁ, A. Comparison of data from smartphones and specialised devices. In *Proceedings of the 24th Conference STUDENT EEICT 2018*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2018. s. 28-30. ISBN: 978-80-214-5614-3.
- [36] JARKOVSKÝ, J.; DUŠEK, L. Biostatistika (ASTA) [prezentácie]. [cit. 2018-05-17]

Zoznam symbolov, veličín a skratiek

REM	-	rapid eye movement
OLED	-	organic light-emitting diode
LPF	-	lowpass filter
TA signál	-	triaxial accelerometer signal
SMA	-	signal magnitude area
SVM	-	signal magnitude vector
FFT	-	fast Fourier transform
ČSÚ	-	český statistický úřad
RMS	-	root mean square
DP	-	dolná propust
EMD	-	empirická modálna dekompozícia
IMF	-	intrinsic mode functions
MLA	-	machine learning algorithm
MEMS	-	microelectromechanical systems
KNN	-	K Nearest Neighbours
DTC	-	Decision Tree Classifiers
HMM	-	Hidden Markov Models

Zoznam príloh

8.1 Obsah priloženého CD

1. Bakalárska práca (formát PDF)
2. Zložka Signály a algoritmy
 - testovacie signály (formát TXT/ CSV)
 - skript pre načítanie testovacích signálov a pre výpočet ich chýb – signály.m
 - skript pre rozšírený algoritmus detekcie pádu – pad.m
 - skript pre krokomer 1 – krokomer1.m
 - skript pre krokomer 2 – krokomer2.m
 - skript pre vzory signálov – vzory.m
 - funkcia pre EMD – eemd.m