



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

KROKOMĚR A DETEKCE PÁDU

PEDOMETER AND FALL DETECTION

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Sofia Vraňáková

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Andrea Němcová

BRNO 2019



Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Sofia Vraňáková

ID: 195202

Ročník: 3

Akademický rok: 2018/19

NÁZEV TÉMATU:

Krokoměr a detekce pádu

POKYNY PRO VYPRACOVÁNÍ:

1) Prostudujte možnosti detekce a počítání kroků a detekce pádu pomocí chytrého telefonu nebo náramku Axivity. 2) Nasnímejte testovací data a vytvořte algoritmus krokoměru. 3) Nasnímejte testovací data a vytvořte algoritmus pro detekci pádu. 4) Pomocí chytrého telefonu nebo náramku Axivity nasnímejte alespoň 10 signálů běžné denní aktivity včetně chůze a simulace pádu. 5) Zkombinujte oba algoritmy do jednoho finálního, který bude umět detekovat a počítat kroky a detekovat pád v signálech nasnímaných při běžných denních činnostech. 6) Optimalizujte algoritmus, vyhodnoťte jeho přesnost, porovnejte ho s dalšími algoritmy a diskutujte výhody a nevýhody.

DOPORUČENÁ LITERATURA:

[1] KANG, X., B. HUANG a G. QI. A Novel Walking Detection and Step Counting Algorithm Using Unconstrained Smartphones. Sensors [online]. 2018, 18(1), 1-15. DOI: 10.3390/s18010297. ISBN 1424-8220.

[2] KORATS, G., J. HOFMANIS, A. SKORODUMOV a E. AVOTS. Fall detection algorithm in energy efficient multistate sensor system. In: 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) [online]. IEEE, 2015, 2015, s. 4974-4977. DOI: 10.1109/EMBC.2015.7319508. ISBN 978-1-4244-9271-8.

Termín zadání: 4.2.2019

Termín odevzdání: 24.5.2019

Vedoucí práce: Ing. Andrea Němcová

Konzultant:

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

Práca je zameraná na problematiku snímania ľudskej aktivity pomocou inerciálnych senzorov zabudovaných v inteligentných zariadeniach a následnej detekcii chôdze, krokov a pádu zo signálu nasnímaného akcelerometrom v smartfóne.

Detekcia chôdze je prevedená s využitím obálky signálu, prvej diferencie signálu a smerodajnej odchýlky signálu. Detekcia krokov je implementovaná pomocou metódy vyhľadávania maxim a metódy prispôbenej filtrácie. Detekcia pádu je realizovaná pomocou metódy vyhľadávania maxim a miním a použitia vhodných prahových hodnôt.

Kľúčové slová

Akcelerometer, inteligentný telefón, detekcia chôdze, detekcia krokov, detekcia pádu

Abstract

This work is focused on the issue of human activity sensing using inertial sensors built into intelligent devices and followed by detection of walk, detection of steps and fall from the accelerometer-scanned signal in the smartphone.

The walk detection is performed by using signal envelope, a first signal difference and a standard deviation of the signal. The step detection is implemented by using the method of searching local maximum values and the customized filtering method. Fall detection is realized by using the method of searching maximum and minimum values and using the appropriate threshold values.

Keywords

Accelerometer, smartphone, walk detection, step detection, fall detection

Bibliografická citácia:

VRAŇÁKOVÁ, Sofia. *Krokoměr a detekce pádu*. Brno, 2019. 54 s. Bakalárska práca. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedúca práce Ing. Andrea Němcová.

Prehlásenie

"Prehlasujem, že svoju záverečnú prácu na tému „*Krokoměr a detekce pádu*“ som vypracovala samostatne pod vedením vedúcej bakalárskej práce a s použitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.“

Ako autorka uvedenej záverečnej práce ďalej prehlasujem, že v súvislosti s vytvorením tejto záverečnej práce som neporušila autorské práva tretích osôb, najmä som nezasiahla nedovoleným spôsobom do cudzích autorských práv osobnostných a som si plne vedomá následkov porušenia ustanovení § 11 a nasledujúcich autorského zákona č. 121/2000 Zb., vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia časti druhej, hlavy VI. diel 4 Trestného zákonníka č. 40/2009 Zb.

V Brne dňa 24.5.2019

.....
Podpis autorky

Pod'akovanie

Ďakujem vedúcej bakalárskej práce Ing. Andrei Němcovej za účinnú metodickú, pedagogickú a odbornú pomoc a ďalšie cenné rady pri spracovaní mojej bakalárskej práce. Ďalej ďakujem mojej rodine a priateľom za neutíchajúcu podporu pri štúdiu a vypracovávaní tejto práce.

V Brne dňa 24.5.2019

.....
Podpis autorky

Obsah

Úvod.....	9
1 Možnosti detekcie aktivity pomocou inteligentného telefónu	11
1.1 Senzory	11
1.1.1 Gyroskop	12
1.1.2 Akcelerometer	13
1.2 Zariadenia používané ako snímače aktivity	15
1.3 Snímané aktivity	17
1.3.1 Krok.....	17
1.3.2 Pád.....	18
1.3.3 Ostatné aktivity	18
1.4 Používané algoritmy	19
1.4.1 Detekcia krokov	19
1.4.2 Detekcia pádu	20
2 Krokomer.....	22
2.1 Snímanie signálu	22
2.2 Predspracovanie signálu	23
2.3 Detekcia krokov	24
2.3.1 Vyhľadávanie peakov.....	25
2.3.2 Prispôsobená filtrácia	26
3 Detekcia pádu.....	28
3.1 Snímanie signálu	28
3.2 Predspracovanie signálu	28
3.3 Detekcia pádu.....	29
4 Segmentácia chôdze zo signálu bežnej dennej aktivity	32
4.1 Obálka signálu	32
4.2 Prvá diferencia signálu.....	34
4.3 Smerodajná odchýlka.....	36
4.4 Výsledná detekcia chôdze	38
5 Výsledný algoritmus	41
6 Meranie	44
7 Výsledky.....	45
Diskusia	48
Záver.....	51
Literatúra.....	52

Zoznam obrázkov

Obrázok 1 : Príklady umiestnenia inerciálnych senzorov na ľudskom tele [4]	12
Obrázok 2: Smery detekovaných uhlových rýchlostí gyroskopom [6]	12
Obrázok 3: Časti MEMS gyroskopu [5]	13
Obrázok 4: MEMS akcelerometer [10]	14
Obrázok 5: Rozloženie osí v trojosovom akcelerometri v telefóne [10]	15
Obrázok 6: Apple iWatch [13]	16
Obrázok 7: Schéma kroku [15]	17
Obrázok 8: Typický tvar pádu a následnosť špičiek	18
Obrázok 9: Ukážka aplikácie na zaznamenávanie aktivity Huawei Health	19
Obrázok 10: Dáta namerané akcelerometrom	23
Obrázok 11: Nasnímané dáta po úprave Euklidovskými vzdialenosťami (hore),	24
Obrázok 12: Schéma algoritmu predspracovania signálu na detekciu krokov	24
Obrázok 13: Počet krokov detegovaných v signáli s použitím rôznych prahových	25
Obrázok 14: Schéma algoritmu na detekciu krokov pomocou vyhľadávania peakov	26
Obrázok 15: Počet krokov detegovaných po prispôsobenej filtrácii s použitím	27
Obrázok 16: Schéma algoritmu na detekciu krokov pomocou prispôbeného filtra	27
Obrázok 17: Dáta nasnímané akcelerometrom	28
Obrázok 18: Upravené dáta pomocou Euklidovskej vzdialenosti (hore),	29
Obrázok 19: Schéma algoritmu na predspracovanie signálu na detekciu pádu	29
Obrázok 20: Výsledná detekcia pádu	30
Obrázok 21: Schéma algoritmu na detekciu pádu	31
Obrázok 22: Obálka signálu	33
Obrázok 23: Schéma algoritmu na detekciu chôdze s využitím obálky signálu	33
Obrázok 24: Detekcia chôdze pomocou obálky signálu (chôdza – červená)	34
Obrázok 25: Prvá diferencia signálu bežnej aktivity	35
Obrázok 26: Schéma algoritmu na detekciu chôdze s využitím prvej diferencie	35
Obrázok 27: Detekcia chôdze pomocou prvej diferencie (chôdza - červená)	36
Obrázok 28: Schéma algoritmu na detekciu chôdze s využitím smerodajnej odchýlky	37
Obrázok 29: Detekcia chôdze pomocou smerodajnej odchýlky (chôdza – červená)	38
Obrázok 30: Schéma výsledného algoritmu na detekciu chôdze	39
Obrázok 31: Porovnanie metód na detekciu chôdze (chôdza - červená)	40
Obrázok 32: Detekcia chôdze vrátane pádu	41
Obrázok 33: Detekcia chôdze po vynechaní intervalu s pádom	42
Obrázok 34: Výsledný algoritmus	42
Obrázok 35: Výsledná detekcia chôdze a pádu	43

Zoznam tabuliek

Tabuľka 1: Dĺžky signálov	44
Tabuľka 2: Presnosť detekcie chôdze	45
Tabuľka 3: Výsledky detekcie krokov – metóda vyhľadávania peakov	46
Tabuľka 4: Výsledky detekcie krokov - metóda prispôbeného filtra	46
Tabuľka 5: Výsledky detekcie pádu	47
Tabuľka 6: Presnosti detekcie chôdze od iných autorov	48
Tabuľka 7: Úspešnosť algoritmov detekcie pádu od iných autorov	49
Tabuľka 8: Odchýlky algoritmov detekcie krokov od iných autorov	49

Úvod

Monitorovanie ľudskej aktivity zaujímalo ľudstvo už odpradáva. Začínalo ako metóda merania vzdialenosti pomocou jednotiek založených na ľudskom tele, napríklad palec (jeho šírka), ruka (šírka dlane) alebo stopa (dĺžka chodidla). Slovo míľa je odvodené od latinského výrazu milia passum, čo znamená „jeden tisíc krokov“. V neskorších časoch sa o rozvoj monitorovania aktivity zaslúžil aj Leonardo da Vinci, ktorý vytvoril prvé mechanické počítadlo krokov. Bolo pripevnené na páse a jeho súčasťou bolo dlhé pákové rameno pripevnené na stehno. Keď sa stehno pohlo dopredu a dozadu pri chodení, ozubené kolieska sa otočili a zaznamenal sa krok [1].

Heslo „10 000 krokov za deň“, ktoré je vo veľkej miere používané aj dnes, má korene v Japonsku a vzniklo okolo roku 1965, krátko po olympijských hrách. Tento počet krokov bol považovaný za správne množstvo fyzickej aktivity, ktoré je dostatočné pre zníženie rizika koronárnych chorôb srdca [1].

V dnešnej dobe je odporúčanie Svetovej zdravotníckej organizácie (WHO) pre dospelých vo veku 18 až 64 rokov aspoň 150 minút aeróbnej aktivity strednej intenzity za týždeň alebo 75 minút aeróbnej aktivity vysokej intenzity za týždeň pre zlepšenie kardiorespiračného a svalového zdravia, zdravia kostí a zníženia pravdepodobnosti objavenia Parkinsonovej choroby alebo depresie [2].

Vo všeobecnosti, ľudia ktorí vedú viac aktívny život, majú v porovnaní s ich menej aktívnymi rovesníkmi nižšie riziko koronárnych srdečných chorôb, vysokého krvného tlaku, mozgovej mŕtvice, diabetu druhého typu, metabolického syndrómu, rakoviny prsníka a hrubého čreva, a pri úrazoch majú tiež nižšie riziko, že u nich nastane zlomenina bedra alebo chrbtice [2].

Práve pre vyššie uvedené dôvody sa v poslednej dobe rozmohlo monitorovanie fyzickej aktivity pomocou rôznych zariadení, ako sú fitness náramky, inteligentné hodinky a v neposlednom rade pomocou inteligentných telefónov, čoho dôkazom je aj štatistika predaja fitness náramkov Fitbit, ktorých počet predaných kusov sa zvýšil z 58 000 v roku 2010 na 21 355 000 v roku 2015 [1]. Tieto zariadenia fungujú na princípe snímania aktivity pomocou rôznych senzorov, napríklad akcelerometra, gyroskopu alebo GPS.

Problematika snímania ľudskej aktivity nezahŕňa len rozpoznávanie rôznych aktivít či počítanie krokov a prejdenej vzdialenosti, ale aj detekciu pádu. Keďže populácia na celom svete starne rastúcim tempom, vzrastajú obavy kvôli zdravotným rizikám, ktoré môže spôsobiť pád najmä starším ľuďom. Podľa štatistického výskumu v USA jeden zo štyroch

Američanov starších ako 65 rokov padne každý rok, každých 11 sekúnd ošetrujú staršieho človeka na urgentnom príjme v dôsledku pádu a každých 19 minút umrie senior na zranenia spôsobené pádom [3]. Práve kvôli týmto obavám sa v posledných rokoch rozbehlo veľa výskumov, ktoré sa zaoberajú odlišením pádu od ostatných denných aktivít, ako je chodenie, behanie, cvičenie, atď. Hlavnou snahou je identifikovať pád čo najskôr kvôli zamedzeniu vyššie zmienených následkov pádu.

Táto práca sa zaoberá monitorovaním fyzickej aktivity ľudí pomocou inteligentného telefónu a následnou detekciou chôdze, krokov a pádov pomocou rôznych metód zo signálu nameraného zo zabudovaného akcelerometra v telefóne.

1 Možnosti detekcie aktivity pomocou inteligentného telefónu

Množstvo štúdií z posledných rokov považuje monitorovanie denných aktivít a správania za jeden z najdôležitejších indikátorov zdravotného stavu človeka. Podľa týchto štúdií je aktivita človeka vo veľkej miere spojená s mnohými civilizačnými chorobami, napríklad obezitou [4].

Existujú dve možnosti sledovania týchto aktivít. Prvá je rozmiestnenie diaľkových senzorov, napríklad kamier, radarov alebo infračervených snímačov na miestach s vysokým pohybom ľudí (parkoviská, nákupné centrá, letiská, atď.). Problémom týchto snímačov je hlavne to, že sú väčšinou fixne umiestnené na jednom mieste, v dôsledku čoho strácame informáciu o aktivite človeka v momente, ako opustí zorné pole senzoru [4].

Ďalšou možnosťou je umiestnenie inerciálnych senzorov priamo na ľudskom tele, ktoré monitorujú bezprostredne pohyb častí ľudského tela. Medzi tieto senzory sa zaraďujú napríklad akcelerometer alebo gyroskop.

1.1 Senzory

S pokrokom v oblasti mikroelektromechanických systémov sa inerciálne senzory stali populárnymi pre monitorovanie ľudských aktivít, a to najmä vďaka ich nízkej cene, malým rozmerom, a možnosti zabudovania do osobných prenosných zariadení, ako sú smartfóny, hodinky, topánky, atď. [4].

Rozličné senzory umiestnené na rôznych častiach ľudského tela budú snímať rozdielne signály, aj keď budú monitorovať tú istú aktivitu. Preto aj minimálne posunutie alebo nesprávne umiestnenie senzoru môže narušiť senzitivitu senzoru a tým pádom aj následná analýza bude nepresná [4].

Ako je možné vidieť na obrázku 1, je naozaj veľa možností umiestnenia senzorov – na stehne (napríklad pomocou smartfónu), na členku, na zápästí (pomocou fitness náramku či inteligentných hodínok) alebo na hlave (v slúchadlách). Vo všetkých zobrazených zariadeniach sa využíva monitorovanie pomocou troch najrozšírenejších senzorov: gyroskop, akcelerometer a GPS. Tieto senzory sú zabudované taktiež v smartfónoch.

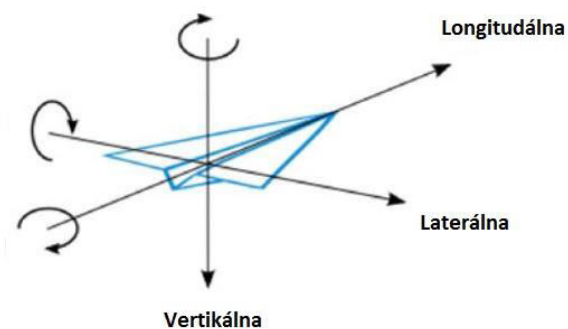


Obrázok 1 : Príklady umiestnenia inerciálnych senzorov na ľudskom tele [4]

1.1.1 Gyroskop

Gyroskopy sú zariadenia založené na snímaní uhlovej rýchlosti pri rotácii zariadenia, a tým pomáhajú určovať aktuálnu orientáciu zariadenia alebo zmeny v jeho orientácii. Existuje mnoho typov gyroskopov, ktoré sú založené na rôznych fyzikálnych princípoch a technológiách, napríklad mechanické gyroskopy, optické gyroskopy, gyroskopy založené na vláknovej optike, laserové gyroskopy alebo MEMS gyroskopy [5].


Orientácia zariadenia sa vypočíta z uhlovej rýchlosti detegovanej gyroskopom a je vyjadrená v radiánoch za sekundu (rad/s) na troch osách (longitudinálna, laterálna a vertikálna), ako je možné vidieť na obrázku 2.



Obrázok 2: Smery detekovaných uhlových rýchlostí gyroskopom [6]

V prenosných zariadeniach sa v súčasnosti používajú MEMS – Micro-Electro-Mechanical, teda mikroelektrické - gyroskopy. Tento typ využíva vibračný mechanický element na meranie uhlovej rýchlosti. Neobsahujú rotujúce časti, ktoré vyžadujú ložiská, a to vedie

k ich miniaturizácii. Vibračný mechanický element je založený na prenose energie medzi dvoma vibračnými módmí spôsobenými Coriolisovým zrýchlením. Skladá sa z rámu, rezonujúcej časti, pružiniek, ktoré sú umiestnené v 90° uhloch od pohybu rezonujúcej časti, a časti na nasnímanie posunutia rámu cez kapacitnú transdukciu v dôsledku sily spôsobenej rezonujúcou časťou (obrázok 3) [7].



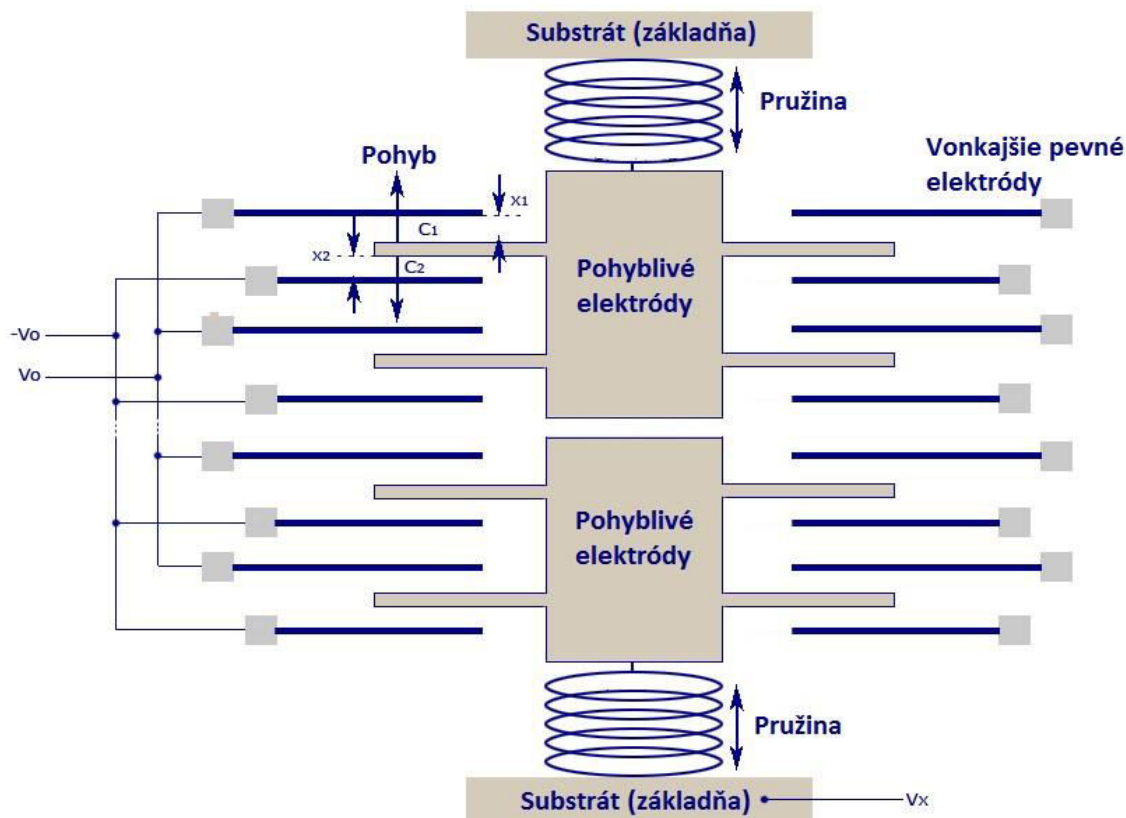
Obrázok 3: Časti MEMS gyroskopu [5]

Hlavné problémy s gyroskopmi sú spojené s nepresnosťami v meraní uhlovej rýchlosti. Senzitivita MEMS gyroskopu môže byť vylepšená pomocou zhodných rezonančných frekvencií vo všetkých smeroch a pomocou zníženia trecej sily [5].

1.1.2 Akcelerometer

Tento typ senzoru sa často využíva v navigačných systémoch, automobilových airbagových systémoch a systémoch na ovládanie pohybu. Akcelerometre fungujú na základe rôznych fyzikálnych princípov kvôli ich širokému poľu využitia – poznáme termálne, optické, kapacitné alebo piezoelektrické akcelerometre [8]. V prenosných zariadeniach na monitorovanie pohybových aktivít osôb sa používajú prevažne kapacitné akcelerometre. Tieto senzory snímajú zrýchlenie pôsobiace na osoby alebo objekty, ktorého jednotky sú buď metre za sekundu na druhú (m/s^2) alebo g, ktoré udáva násobky normálneho tiažového zrýchlenia. Každé prenosné zariadenie ale obsahuje trochu inak orientovaný akcelerometer, a preto sa namerané dáta pomocou rôznych telefónov môžu líšiť [6].


Kapacitné akcelerometre majú viacero výhod, ktoré pramenia hlavne z pokroku v oblasti MEMS (Micro-Electro-Mechanical Systems). Fungujú na princípe merania rozdielu kapacít medzi vonkajšími elektródami, ktoré sú pevne fixované, a pohyblivými hrebeňovými elektródami (obrázok 4). Torzný pohyb visiacych elektród v dôsledku vonkajšieho zrýchlenia vedie k zmene posunu vzájomne prekrytých častí elektród a teda k zmene kapacitancie [9]. Medzi tieto výhody patria nízka spotreba energie, vysoká odolnosť voči zmenám teploty, nízka cena a výhodná integrácia do zariadení [8].



Obrázok 4: MEMS akcelerometer [10]

Piezoelektrické akcelerometre dominujú v oblasti monitorovania šoku a vibrácií, napríklad seizmometre. Aj keď tieto akcelerometre ponúkajú nízky hluk, široký dynamický a frekvenčný rozsah, nie sú schopné merať statické a kvázistatické zrýchlenie [8]. Fungujú na princípe piezoelektrického javu, a teda že ak na piezoelektrický materiál (väčšinou kremič) pôsobí sila, ktorá ho zdeformuje, tento materiál generuje elektrické napätie, ktoré je merateľné.

Pre mnohé aplikácie, ktoré boli zmienené vyššie, je potrebné zaznamenávanie zrýchlenia v troch osách (obrázok 5) [6].



Obrázok 5: Rozloženie osí v trojosovom akcelerometri v telefóne [10]

1.2 Zariadenia používané ako snímače aktivity

Najpoužívanejšie zariadenia na snímanie aktivity sú fitness náramky a smartfóny. Obe zariadenia obsahujú senzory, ktoré snímajú aktivitu priamo z povrchu ľudského tela – sú pripravené na častiach tela, ktoré sa pri pohybe špecificky hýbu, napríklad končatiny.

Fitness náramky sú zariadenia, pomocou ktorých môžeme snímať rôzne aktivity pomocou akcelerometra, napríklad merať tepovú frekvenciu, počítať kroky, a na základe týchto údajov dokážu vypočítať ďalšie údaje, akým je napríklad počet spálených kalórií. Tieto náramky dokážu rozlíšiť, či ich nositeľ odychuje, alebo je fyzicky aktívny. Niektorí výrobcovia dokonca deklarujú, že tieto zariadenia vedia od seba odlišiť rôzne spánkové fázy. Výstup z akcelerometra, ktorý je triaxiálny, je možné použiť aj na detekciu a počítanie krokov. Niektoré pokročilejšie náramky (smartwatch) môžu slúžiť aj ako hodinky, prehrávače hudby, dajú sa na nich prezerať dokumenty alebo vybavovať maily či sprostredkovať hovory. Tieto zariadenia sa pripájajú na smartfón prostredníctvom Bluetooth a v poslednom čase ich počet rapídne vzrastá a skoro každá značka, ktorá vyrába smartfóny, produkuje aj fitness náramky či smartwatch – či už Apple iWatch, Xiaomi Mi Band alebo Huawei Band.

Apple iWatch okrem zaznamenávania tepovej frekvencie počas dňa upozornia užívateľa, ak u neho zaznamenajú nezvyčajne vysokú alebo nízku tepovú frekvenciu (obrázok 6). Taktiež dokáže detegovať pád, pri ktorom pošlú užívateľovi upozornenie, ktoré môže pri nesprávnej detekcii užívateľ ľahko zrušiť, a ak nezaznamenajú žiadnu aktivitu po dobu 60 sekúnd, pošlú hlásenie záchranej služby a kontaktom, ktoré sú uložené ako núdzové, a na displeji zobrazia medicínske informácie pre zdravotnícky personál. Užívateľia ich môžu využívať aj pri relaxáciách, na sledovanie príjmu tekutín či monitorovanie spánku [12].



Obrázok 6: Apple iWatch [13]

Väčšina týchto zariadení je určená pre užívateľov, a nie na vedecké účely – a teda sa z nich nedajú dostať surové (raw) dáta, ktoré sú pre potreby užívateľa irelevantné. Avšak existujú aj náramky, ktoré túto možnosť získavania dát poskytujú – napríklad náramok Axivity AX3 [14].


Smartfón v súčasnej dobe využíva skoro každý človek. Obsahuje mnoho senzorov, napríklad akcelerometer, gyroskop, magnetometer, GPS, mikrofón alebo fotoaparát, pomocou ktorých sa dá namerať pestrá paleta aktivít človeka. Väčšinou sa tieto senzory kombinujú na určenie aktivity (napríklad akcelerometer alebo gyroskop s GPS pre lepšie určenie počtu krokov, prejdenej vzdialenosti a rozlíšenie typu aktivity).

1.3 Snímané aktivity

Počas dňa človek vykoná radu aktivít, ktoré sa dajú nasnímať pomocou akcelerometra. Jednou zo základných snímaných aktivít je krok, ktorých každý z nás spraví denne niekoľko sto až tisíc, a ďalej napríklad chôdza alebo beh.

1.3.1 Krok

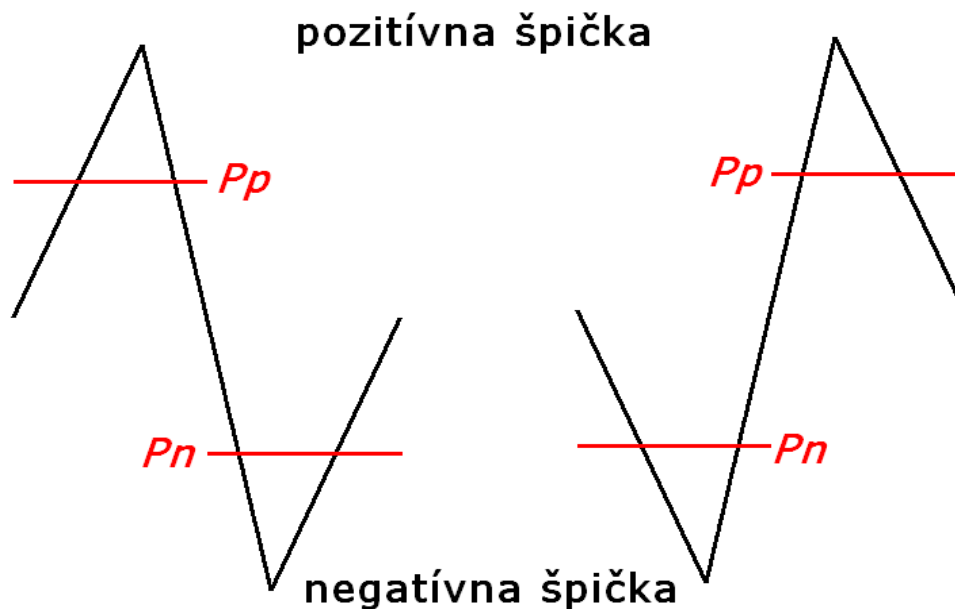
Najskôr je potrebné si zdefinovať, čo to vlastne krok je a ako sa prejaví na výchylke akcelerácie v nameranom signáli. Pohyb nohy počas kroku sa dá rozdeliť do dvoch fáz: prvou je fáza kyvu, pri ktorej sa noha presúva dopredu spoza druhej nohy, a druhá fáza je fáza dotyku chodidla so zemou. Počas prvej fázy má zrýchlenie negatívnu špičku, za ktorou nasleduje pozitívna špička patriaca do druhej fázy, a následne prechádza do negatívnej špičky patriacej druhej fáze. Táto následnosť špičiek patrí jednému kroku (obrázok 7) [15].



Obrázok 7: Schéma kroku [15]

1.3.2 Pád

Tak ako krok, aj pád má svoj typický tvar, ktorý sa prejaví na výchylke akcelerácií v nameranom signáli. Pád sa skladá z dvoch častí – negatívnej a pozitívnej špičky. Každá z týchto špičiek musí dosiahnuť určitej prahovej hodnoty. Z poradia týchto špičiek sa dá určiť, do ktorého smeru padal človek. Na rozlíšenie pádu vpred a vzad sa používa kanál v smere osi x. Pri páde vpred predchádza negatívna špička pozitívnu a pri páde vzad je to naopak. Ďalej, na rozlíšenie pádu doľava a doprava sa používa kanál v smere osi y. Typická postupnosť špičiek pri páde vľavo je negatívna špička, za ktorou nasleduje pozitívna špička. Pre pád vpravo je postupnosť opačná [16]. Typický tvar pádu v akcelerometrickom signáli je zobrazený na obrázku 8.



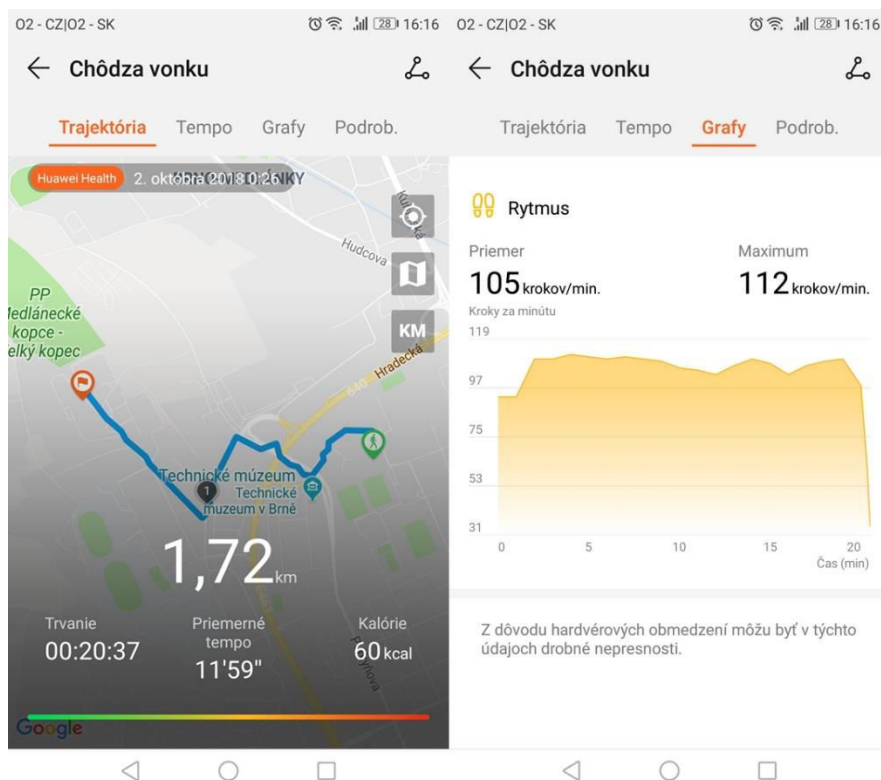
Obrázok 8: Typický tvar pádu a následnosť špičiek
(P_p – pozitívna prahová hodnota, P_n – negatívna prahová hodnota)

1.3.3 Ostatné aktivity

Pri snímaní dennej aktivity človeka sa dajú rozlíšiť rôzne druhy aktivity. Tieto aktivity sú buď statické, ako napríklad státie, sedenie, alebo ležanie, a dynamické, ako napríklad chôdza, beh, bicyklovanie, chôdza do kopca a podobne [17]. Každá táto aktivita má svoje špecifické zobrazenie v nasnímanom signáli buď pomocou akcelerometra alebo gyroskopu, aj keď niekedy sa jednotlivé aktivity nedajú celkom dobre rozlíšiť.

Tieto nasnímané signály sa dajú vyhodnotiť pomocou rôznych mobilných aplikácií. Najrozšírenejšie sú aplikácie na počítanie krokov – tzv. pedometre, ktoré majú mnohé

smartfóny už predinštalované od výrobcu. Ďalej existujú aplikácie, ktoré slúžia ako na počítanie krokov, tak aj odmeranie prejdenej vzdialenosti a rozoznanie vykonanej aktivity – či daný človek bežal, kráčaľ alebo bol na turistike. Tieto aplikácie ale z veľkej väčšiny fungujú viac-menej na získavaní dát z GPS (Global Positioning System), a preto sú často nepresné vnútri budov, kde GPS má slabý signál. Ako príklad takejto aplikácie je možné uviesť aplikáciu Huawei Health (obrázok 9), ktorá je zabudovaná do smartfónu využívaného na účely tejto práce od výrobcu.



Obrázok 9: Ukážka aplikácie na zaznamenávanie aktivity Huawei Health

1.4 Používané algoritmy

Po nasnímaní signálu aktivity je potrebné použiť algoritmy, ktoré dokážu z tohto signálu rozpoznať typ aktivity, poprípade detegovať počet krokov alebo pád. Práve na algoritmy pre detekciu krokov a pádu sa zameriavajú nasledujúce podkapitoly.

1.4.1 Detekcia krokov

Algoritmov vytvorených na detekciu krokov existuje hneď niekoľko, a je možné ich rozdeliť do troch hlavných skupín: metódy založené na detekcii maxím (peakov), metódy založené na prechodoch nulou a metódy využívajúce koreláciu [18].

Metóda založená na detekcii peakov si zakladá na predpoklade, že krok je započítaný v prípade, že je detegovaný charakteristický peak (špička) v signáli akcelerácií. Okrem detekcie peakov sa bežne využíva aj s použitím prahovej hodnoty, kedy je krok započítaný v prípade, že je hodnota detegovaného peaku vyššia ako prah. Táto metóda je jednou z najrozšírenejších z dôvodu jej jednoduchosti a jednoduchej implementácie, aj keď výsledok detekcie môže byť ovplyvnený rôznymi externými šumami [18].

V ďalšej kategórii je využívaný prechod nulou. Jej koncept je založený na predstave, že by mal nastať jeden moment nulovej rýchlosti, keď používateľ prejde jeden krok. Tieto algoritmy teda pre stanovenie počtu krokov spočítajú počet prechodov nulou [18].

Tretou kategóriou je využitie počítania korelácie pre určenie počtu krokov. Pri tejto metóde sa vypočíta korelácia akcelerometrických dát so vzorom a ak hodnota korelácie prekročí určitú prahovú hodnotu, je detegovaný krok [18].

V tejto práci je na detekciu krokov používaná metóda detekcie maxím a metóda korelácie s menšími obmenami.

1.4.2 Detekcia pádu

Metódy detekcie pádu sa dajú rozdeliť na tri hlavné kategórie: založené na akustických, vizuálnych a pohybových senzoch. Metódy založené na akustických senzoch detegujú pád napríklad na základe analýzy zvuku získaného mikrofónom alebo monitorovaním vibrácií zeme. Vizuálne založené metódy sa spoliehajú na kamery a pokrok v oblasti počítačového videnia. Aj keď tieto metódy benefitujú z toho, že sú neinvazívne voči ľudskému telu, majú aj radu nevýhod. Oproti tomu využitie kinematických senzorov, akými sú napríklad akcelerometre a gyroskopy, je omnoho praktickejšie. Ako bolo spomenuté vyššie, oba tieto senzory sú už nedeliteľnou súčasťou inteligentných zariadení, ako sú napríklad náramky alebo smartfóny [19].

Algoritmy detekcie pádu sú založené hlavne na princípe rozlíšenia pádu od ostatných aktivít. Taktiež sa dajú rozdeliť do dvoch kategórií: metódy založené na prahových hodnotách a metódy založené na rozpoznávaní vzorov [20].

Metódy založené na prahových hodnotách sú založené na určení rôznych prahových hodnôt na rozlíšenie rôznych aktivít. Medzi výhody týchto metód patrí ich jednoduchosť implementácie a potreba minimálnych výpočtov, a preto sú preferované najmä v systémoch používaných v smartfónoch, ktoré majú limitovanú výpočtovú a pamäťovú

kapacitu. Medzi nevýhody je možné zaradiť počet falošných detekcií pádu z dôvodu zamerania sa len na hodnoty akcelerácii, čo sa dá odstrániť pomocou kontroly orientácie tela po detegovanom páde [20].

Druhou kategóriou sú metódy založené na rozpoznávaní vzorov. Tieto metódy využívajú algoritmy strojového učenia na rozlíšenie pádov a ostatných aktivít na základe podobností so vzormi. V porovnaní s algoritmami, ktoré využívajú prahovú hodnotu, sú viac sofistikované, avšak je otázne či poskytujú lepšiu detekciu [20].

V tejto práci bol na detekciu pádu použitý algoritmus detekcie pádu pomocou prahových hodnôt.

2 Krokomer

Ako bolo preukázané v kapitole 1, ľudská aktivita sa dá monitorovať rôznymi spôsobmi. V tejto a nasledujúcich kapitolách sa zameriam na snímanie a počítanie krokov pomocou akcelerometra zabudovaného v smartfóne, presnejšie Huawei P9 Lite 2016, a aplikácie prepojenej s akcelerometrom Sense it, ktorý bol umiestnený v prednom vrecku nohavíc.

2.1 Snímanie signálu

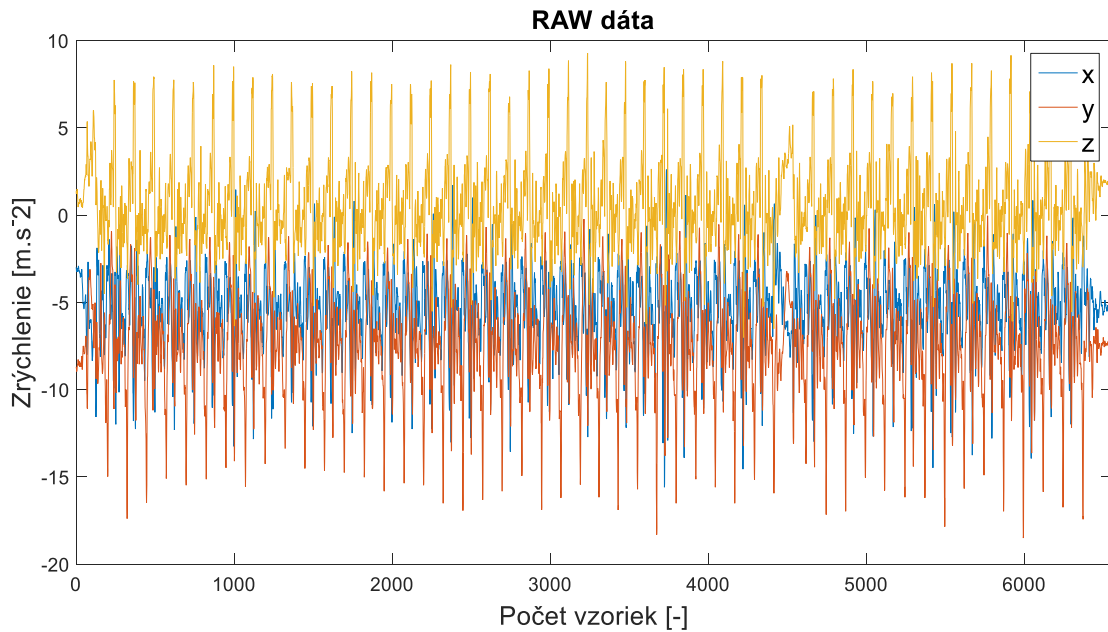
Signál z akcelerometra môžeme snímať na rôznych častiach tela. Smartfón ľudia najčastejšie nosia v prednom vrecku nohavíc, vo vrecku bundy, v ruke (napríklad počas odpisovania na správy) alebo v zadnom vrecku nohavíc.

Pri snímaní signálu je potrebné zvoliť vhodnú vzorkovaciu frekvenciu. Vzorkovacia frekvencia udáva, koľko hodnôt akcelerácie sa nasníma za jednu sekundu, napríklad pri vzorkovacej frekvencii 100 Hz sa nasníma 100 vzoriek za sekundu. Pre presné nameranie signálu musí vzorkovacia frekvencia spĺňať Nyquistov (Shannonov, Kotelníkov) vzorkovací teorém

$$f_{vz} > 2f_{max} \quad (1)$$

ktorý určuje, že vzorkovacia frekvencia musí byť väčšia ako dvojnásobok maximálnej frekvencie signálu, aby sa predišlo aliasingu (prekryvu spektier), a teda strate dát [21]. Podľa štúdie [22] je 98 % energie signálu chôdze nameraných s maximálnou frekvenciou pod 10 Hz a 99 % energie signálu s maximálnou frekvenciou pod 15 Hz. Pri dodržaní rovnice (1) by teda vzorkovacia frekvencia mala byť minimálne 30 Hz. Ďalšia štúdia [23] zaoberajúca sa stanovením vzorkovacej frekvencie pri snímaní ľudskej aktivity zistila, že najmenšie chyby v meraní signálu na rôznych umiestneniach smartfónu boli pri použití vysokých vzorkovacích frekvencií (40-100 Hz). Na druhej strane, nižšia vzorkovacia frekvencia zníži čas potrebný na spracovanie signálu systémom, ktorý je tak viac efektívny a spotrebuje menej energie. V tejto práci bola využitá najvyššia vzorkovacia frekvencia dostupná v aplikácii Sense it, a teda 100 Hz.

Keďže smartfón využíva triaxiálny akcelerometer, výsledný nasnímaný signál (obrázok 10) bude mať tri kanály pre zrýchlenia v osách x, y a z (podkapitola 1.1.3). Každý signál obsahuje okrem zrýchlení nameraných pre chôdzu aj zložku gravitačného zrýchlenia 1G v smere kolmom na zem a šum spôsobený pohybom telefónu vo vrecku, trasom svalom a podobne.



Obrázok 10: Dáta namerané akcelerometrom

2.2 Predspracovanie signálu

Ako už bolo naznačené v podkapitole 1.1, ako výstupný signál z akcelerometra dostaneme zašumený trojkanálový signál. Každý tento kanál obsahuje výchylky zrýchlenia pre osi x, y, z, ktoré ale pre stanovenie počtu krokov musíme spojiť do jedného. Celková hodnota zrýchlenia sa vypočíta pomocou Euklidovských vzdialeností ako


$$|a| = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (2)$$

kde a_x je hodnota zrýchlenia v smere osi x, a_y je hodnota zrýchlenia v smere osi y a a_z je zrýchlenie v smere osi z [23].


Ďalej je potrebné od signálu odčítať hodnotu tiažového zrýchlenia 1G, ktoré v našich zemepisných šírkach dosahuje hodnotu približne $9,81 \text{ m.s}^{-2}$ a je detegovaná v smere osi, ktorá sa nachádza v smere kolmom k zemi, a skresľuje skutočné hodnoty zrýchlenia v danom momente [1]. V tejto práci bolo použité tiažové zrýchlenie, ktoré bolo namerané ako signál aktivity trvajúcej pár sekúnd, počas ktorej sa smartfón nepohyboval.

Následne sa pomocou rovnice (2) upravil výstup signálu a ako tiažové zrýchlenie bola použitá priemerná hodnota tohto signálu.

Keď už je signál aktivity upravený a zbavený tiažového zrýchlenia, je potrebné odfiltrovať šum spôsobený vonkajšími vplyvmi, napríklad trasom svalov alebo pohybom smartfónu po vrecku. Bol použitý filter typu FIR (Finite Impulse Response), teda filter s konečnou impulznou charakteristikou, typu pásmová priepusť s hraničnými frekvenciami 1 a 3,5 Hz, ktoré boli stanovené empiricky. Rozdiely medzi signálom upraveným len pomocou Euklidovských vzdialeností a vyfiltrovaným signálom sú zobrazené na obrázku 11, schéma algoritmu je na obrázku 12.



Obrázok 11: Nasnímané dáta po úprave Euklidovskými vzdialenosťami (hore), dáta po filtrácii (dole)



Obrázok 12: Schéma algoritmu predspracovania signálu na detekciu krokov


2.3 Detekcia krokov

Na určenie počtu krokov sa dá použiť mnoho metód. Táto práca sa zaoberá najmä metódou vyhľadávania maxím alebo špičiek v signáli a metódou prispôbenej filtrácie.

2.3.1 Vyhľadávanie peakov

Pri tejto metóde vychádzame z predstavy kroku z podkapitoly 1.3.1, a teda že jeden krok sa skladá z jednej pozitívnej špičky a dvoch negatívnych špičiek. K detekcii kroku je teda potrebné vyhľadať v signáli pozitívne špičky. Na vyhľadávanie bola použitá funkcia *findpeaks*, ktorá dokáže detegovať lokálne maximá, resp. špičky (peaky) v signáli pri zadaní vstupných kritérií, napríklad minimálnej výšky maxima.

Prahová hodnota (minimálna výška maxima) sa dá určiť rôzne. V rámci vývoja tohto algoritmu boli na signáli, kde bolo pri meraní napočítaných 100 krokov, vyskúšané ako prahové hodnoty smerodajné odchýlky signálu, medián signálu a priemerná hodnota signálu, najlepšie sa osvedčila priemerná hodnota z týchto troch hodnôt, čo je zrejme z obrázku 13. Ďalej je potrebné ošetriť, aby ako kroky boli započítané naozaj len kroky, a preto je potrebné nájsť lokálne minimum pred a za detegovaným lokálnym maximom. Ako krok bude započítaná len tá detegovaná špička, ktorej bude predchádzať aj nadväzovať lokálne minimum. Schéma algoritmu je na obrázku 14.



Obrázok 13: Počet krokov detegovaných v signáli s použitím rôznych prahových hodnôt:

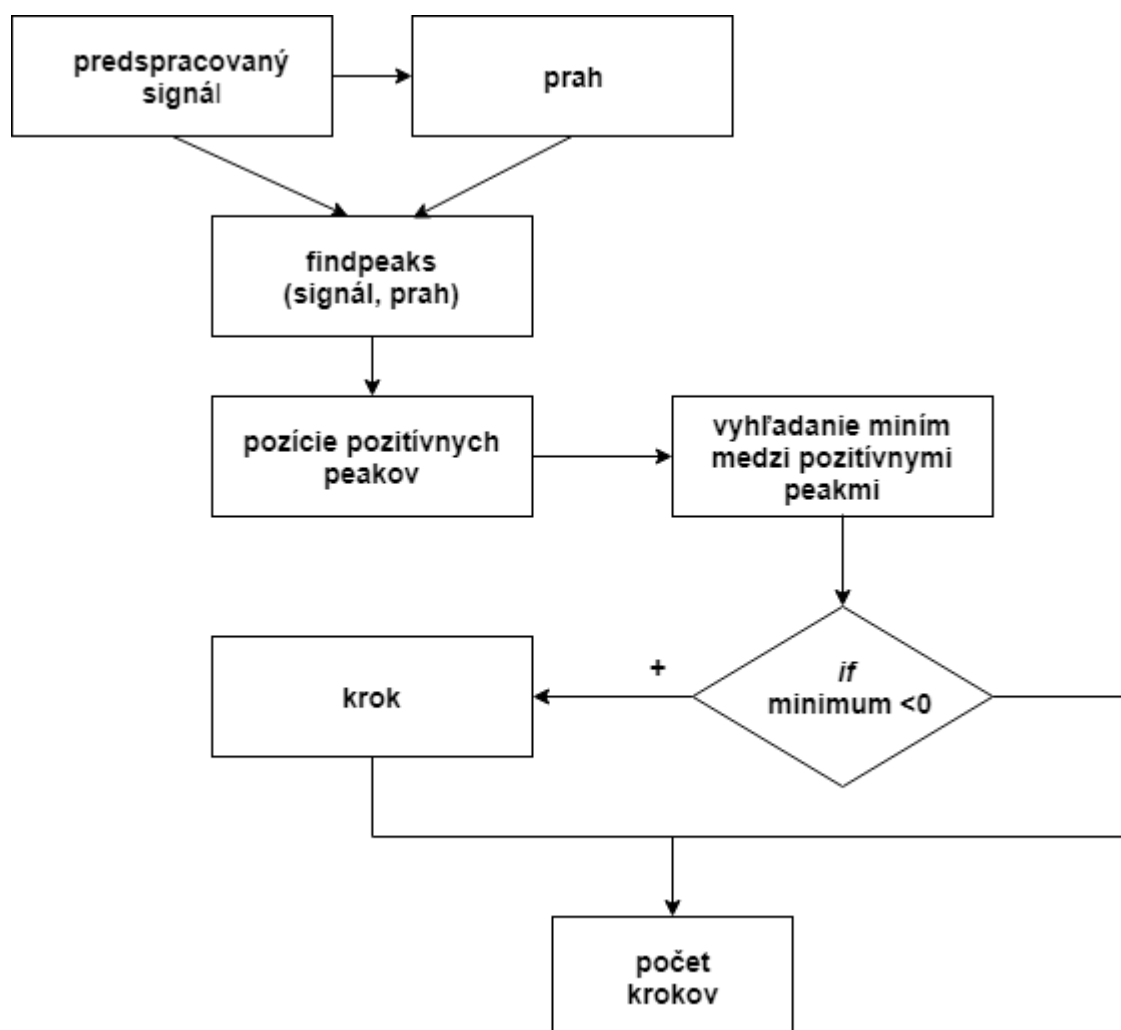
a) smerodajná odchýlka,

b) priemerná hodnota,

c) medián,

d) priemerná hodnota z prahov a), b), c)

(modrá – zrýchlenie, zelené hviezdičky – detegované kroky)



Obrázok 14: Schéma algoritmu na detekciu krokov pomocou vyhľadávania peakov


2.3.2 Prispôbená filtrácia

Táto metóda vychádza z princípu autokorelácie a zo súvislosti korelácie s konvolúciou. Vzájomná korelácia dvoch signálov môže byť realizovaná konvolúciou, ak sa jeden z korelovaných signálov prevedie do reverznej podoby, teda sa obráti v čase. Ak je jeden zo signálov $x(n)$ a druhý $y(n)$, ich vzájomnú koreláciu môžeme zapísať ako

$$r_{yx} = y(n) * x(-n) . \quad (3)$$

V prípade detekcie krokov sa odozva prispôbeného filtra počíta ako konvolúcia signálu aktivity s impulznou charakteristikou v podobe nameraného signálu dvoch krokov, ktorý je obrátený v čase. Výsledkom tejto filtrácie je signál s autokorelačnými špičkami [24]. Pri detekcii krokov postupujeme tak ako v predchádzajúcej metóde. Ako nameraný signál bol taktiež použitý ten, v ktorom bolo pri snímaní napočítaných 100 krokov. Taktiež sa ako prahová hodnota osvedčila priemerná hodnota zo smerodajnej odchýlky, priemernej

hodnoty a mediánu signálu, ako je možné vidieť na obrázku 15 a schému algoritmu je možné vidieť na obrázku 16.

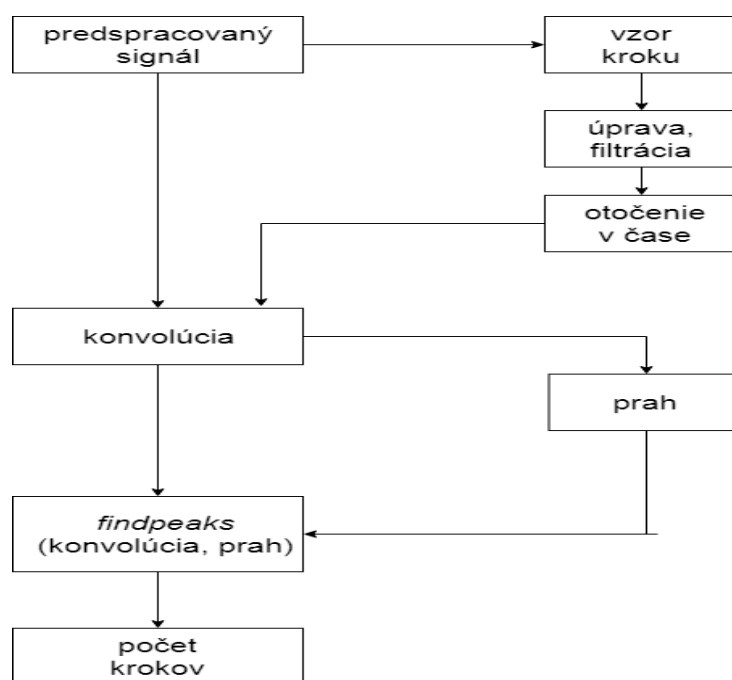


Obrázok 15: Počet krokov detegovaných po prispôsobenej filtrácii s použitím rôznych prahových hodnôt:

- a) smerodajná odchýlka,
- b) priemerná hodnota,
- c) medián,

d) priemerná hodnota z prahov a), b), c)

(modrá – korelačný signál, zelené hviezdičky – detegované kroky)



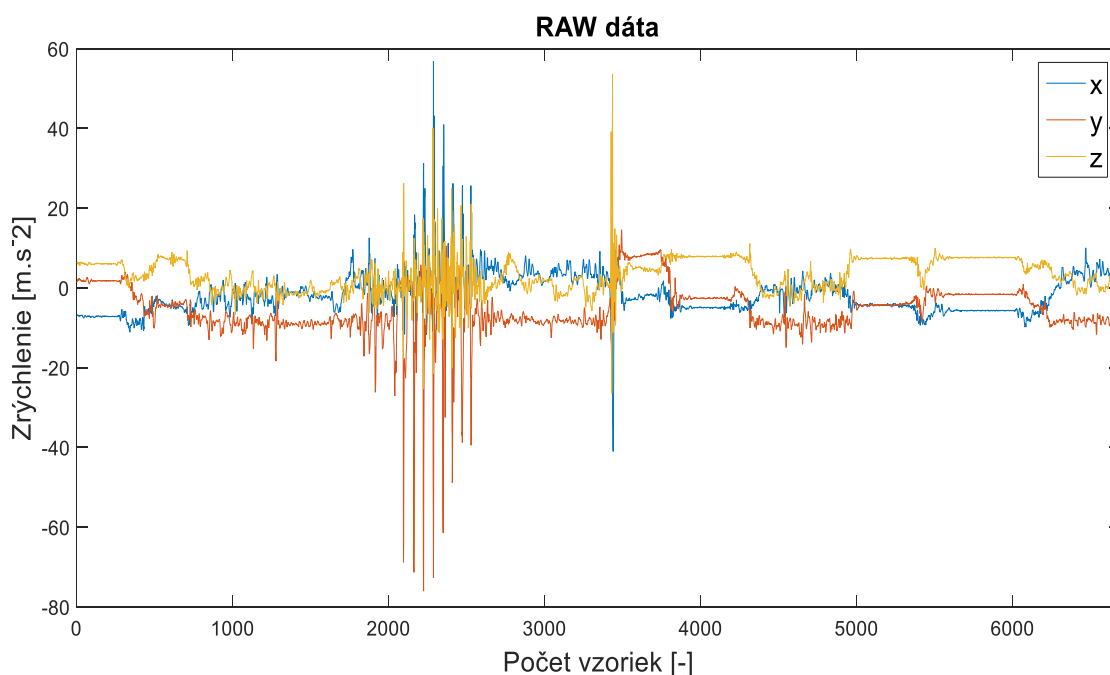
Obrázok 16: Schéma algoritmu na detekciu krokov pomocou prispôsobeného filtra

3 Detekcia pádu

Na detekciu pádu sa dajú použiť rôzne algoritmy. V tejto práci bola použitá metóda založená na prahových hodnotách. Signály z akcelerometra boli namerané, tak ako v prípade krokometru, pomocou aplikácie Sense it a smartfónu Huawei P9 Lite 2016, ktorý bol taktiež umiestnený v prednom vrecku nohavíc.

3.1 Snímanie signálu

Ako bolo spomenuté vyššie, pri tvorbe algoritmu na detekciu pádu bol použitý signál z akcelerometra. Vzorkovacia frekvencia zostane taká istá ako pri snímaní signálu pre počítanie krokov, a teda 100 Hz. Nasnímaný signál má taktiež tri kanály pre zrýchlenia v smere os x, y a z a je zaťažený rovnakým šumom ako v podkapitole 2.1 (obrázok 17).




Obrázok 17: Dáta nasnímané akcelerometrom


3.2 Predspracovanie signálu

Podobne ako bolo zmienené v podkapitole 3.1, signál nasnímaný pomocou akcelerometra v smartfóne bude zašumený a bude mať tri kanály. Pre metódu detekcie pádu používanú v tejto práci je vhodné spojiť tieto kanály do jedného pomocou Euklidovskej vzdialenosti (obrázok 18 hore) podľa rovnice (2), a odčítať hodnotu tiažového zrýchlenia, ktoré bolo získané spôsobom popísaným v podkapitole 2.2. Ďalej je potrebné zbaviť signál šumu. Pre tento účel bol použitý FIR filter typu dolná priepusť s medznou frekvenciou 20 Hz (obrázok 18 v strede) a následne bol použitý priemerovací filter s plávajúcim oknom

s dĺžkou 125 ms, čo predstavuje 13 vzoriek (obrázok 18 dole). Schému predspracovania je možné vidieť na obrázku 19.



Obrázok 18: Upravené dáta pomocou Euklidovskej vzdialenosti (hore), vyfiltrované dáta dolnou priepusťou (v strede) a priemerovacím filtrom (dole)



Obrázok 19: Schéma algoritmu na predspracovanie signálu na detekciu pádu

3.3 Detekcia pádu

Metóda použitá v tejto práci na detekciu pádu je založená na detekcii pomocou prahovej hodnoty, podobne ako pri detekcii krokov v kapitole 2.3. Detekcia pádu je avšak komplexnejší problém ako detekcia krokov. V priebehu empirického skúmania tvarov signálov a ich zmien výchyliek zrýchlenia bola najvyššia nasnímaná výchylka práve pri páde, nasledovalo cvičenie zložené z výskokov a drepov.

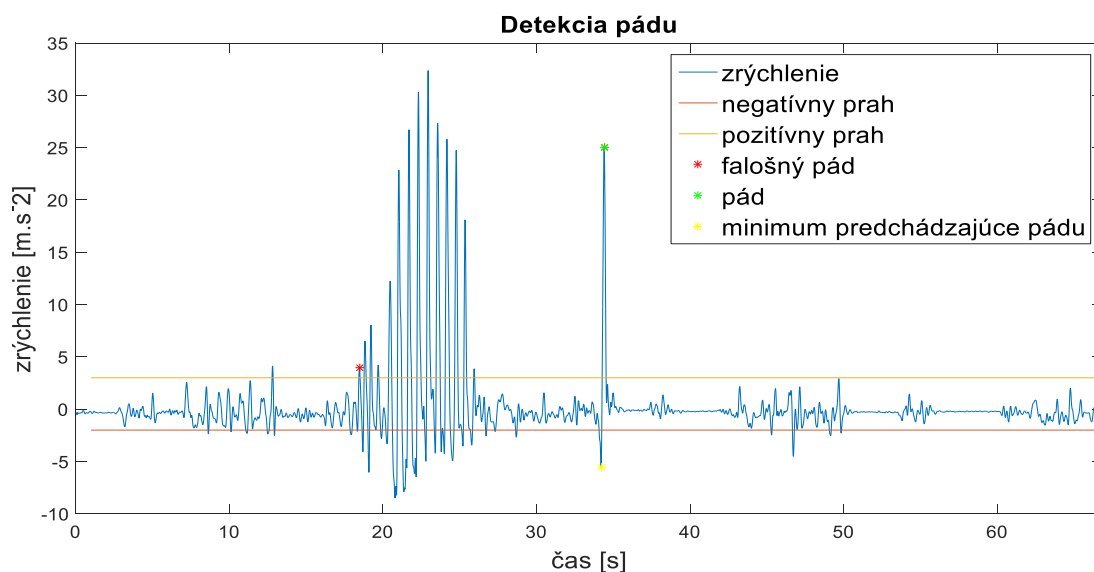
V algoritme sú použité dve prahové hodnoty, jedna kladná a druhá záporná. Ako kladná prahová hodnota bola použitá najvyššia hodnota získaná zo signálu nasnímaného za účelom detekcie krokov zaokrúhlená nahor [25], ako záporná bola použitá tá istá hodnota, iba zaokrúhlená nadol a prevedená do záporných čísel. Ako bolo spomenuté vyššie, pri použití len kladnej prahovej hodnoty a funkcie *findpeaks* sa nadedegujú aj falošné pády, teda aktivity, u ktorých zrýchlenia dosiahnu tejto prahovej hodnoty, ale nie sú to pády. Najskôr sa z falošných pádov odstránia pozície, ktoré sú od seba vzdialené o menej ako

500 vzoriek, keďže tieto výchyľky vznikli pravdepodobne nejakou periodicky sa opakujúcou aktivitou, a tou pád určite nie je.

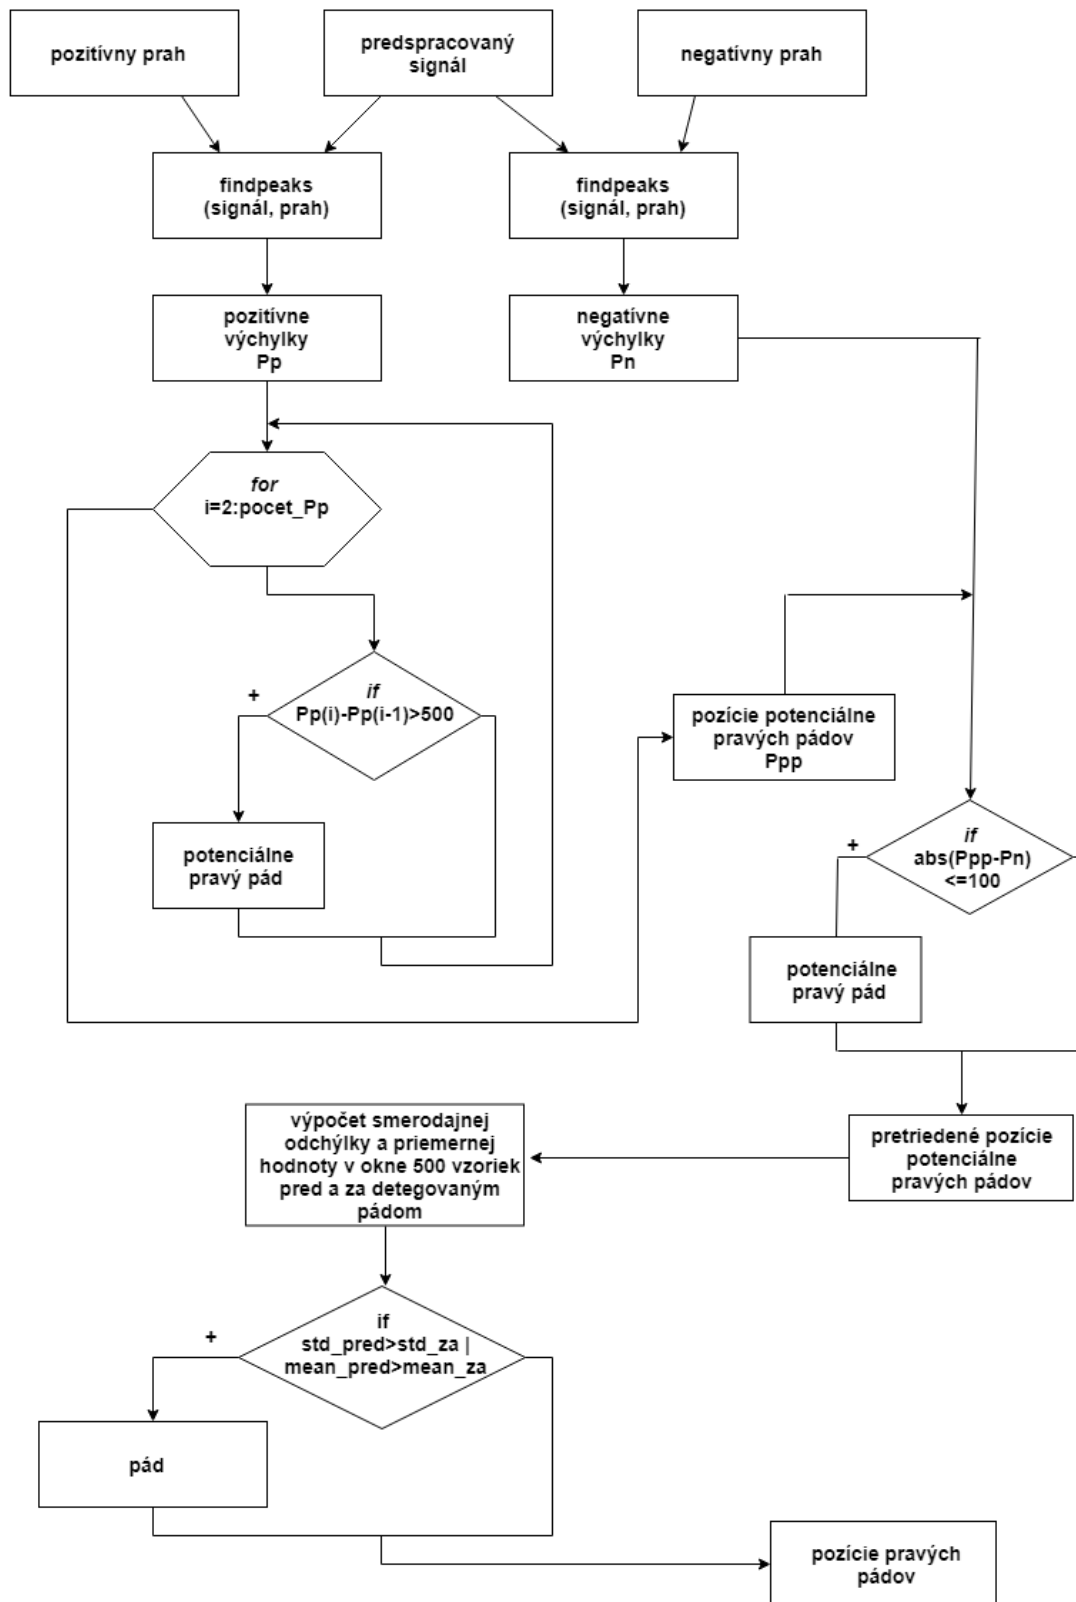
Pravý pád je nadetegovaný len vtedy, ak je v časovom okne do jednej sekundy (100 vzoriek) pred ním alebo za ním detegované lokálne minimum dosahujúce zápornej prahovej hodnoty, a ak je v časovom okne päť sekúnd (500 vzoriek) po detegovanom údajnom páde smerodajná odchýľka alebo priemerná hodnota tohto malého úseku signálu menšia, ako bola päť sekúnd pred údajným pádom.

Výsledná detekcia pádu je vykreslená na obrázku 20. Na tomto obrázku je možné vidieť medzi dvadsiatou a tridsiatou sekundou výchyľky, ktoré presahujú oba prahy, ale nie sú detegované ako pády z dôvodu, že nasledujú periodicky za sebou s rozstupmi menšími ako päť sekúnd (500 vzoriek). Ďalej falošný pád označený červenou hviezdičkou je označený ako falošný z dôvodu, že nespĺňa podmienku stanovenú pre pravý pád, a to, že smerodajná výchyľka alebo priemerná hodnota signálu v okne päť sekúnd po ňom nie je menšia ako päť sekúnd pred ním.

Na obrázku 21 je výsledná schéma detekcie pádu.



Obrázok 20: Výsledná detekcia pádu



Obrázok 21: Schéma algoritmu na detekciu pádu

4 Segmentácia chôdze zo signálu bežnej dennej aktivity

Pre potreby počítania krokov zo signálu bežnej dennej aktivity je potrebné segmentovať časti tohto signálu, v ktorých sa nachádza len chôdza, a nie iné aktivity. Tieto aktivity by mohli skresľovať reálny počet krokov, pretože by ako kroky boli detegované aj aktivity, ktoré majú síce podobný tvar, ale krokmi nie sú. Ďalej segmentovanie chôdze môže byť základom pre rozlíšenie aj ďalších bežných aktivít.

Toto odlíšenie chôdze sa dá implementovať rôznymi spôsobmi, táto práca sa zameriava na metódy využívajúce obálku signálu, ktorá vznikla Hilbertovou transformáciou signálu, prvú diferenciu signálu a smerodajnú odchýlku vzoru chôdze.

4.1 Obálka signálu

Prvá metóda použitá na segmentovanie chôdze zo signálu bežnej aktivity je použitie obálky signálu. Obálka je získaná s využitím analytického signálu a Hilbertovej transformácie.

Analytický signál je komplexný signál s jednostranným spektrom. Tento signál má teda tvar

$$v_n = x_n + jy_n, \quad (4)$$

kde v_n je analytický signál, x_n je jeho reálna zložka a y_n je jeho imaginárna zložka [21].

Analytický signál sa dá získať z reálneho signálu pomocou Hilbertovej transformácie. Pomocou diskkrétnej Fourierovej transformácie sa vypočíta spektrum signálu x_n ako $X(\omega)$, vynuluje sa časť jeho spektra v pásme od polovice vzorkovacej frekvencie až po vzorkovaciu frekvenciu, a po použití inverznej diskkrétnej Fourierovej transformácie sa stane z reálneho signálu komplexný analytický signál. [24]


Samotná obálka predstavuje absolútnu hodnotu analytického signálu

$$env_n = |v_n| = |x_n + jy_n|, \quad (5)$$

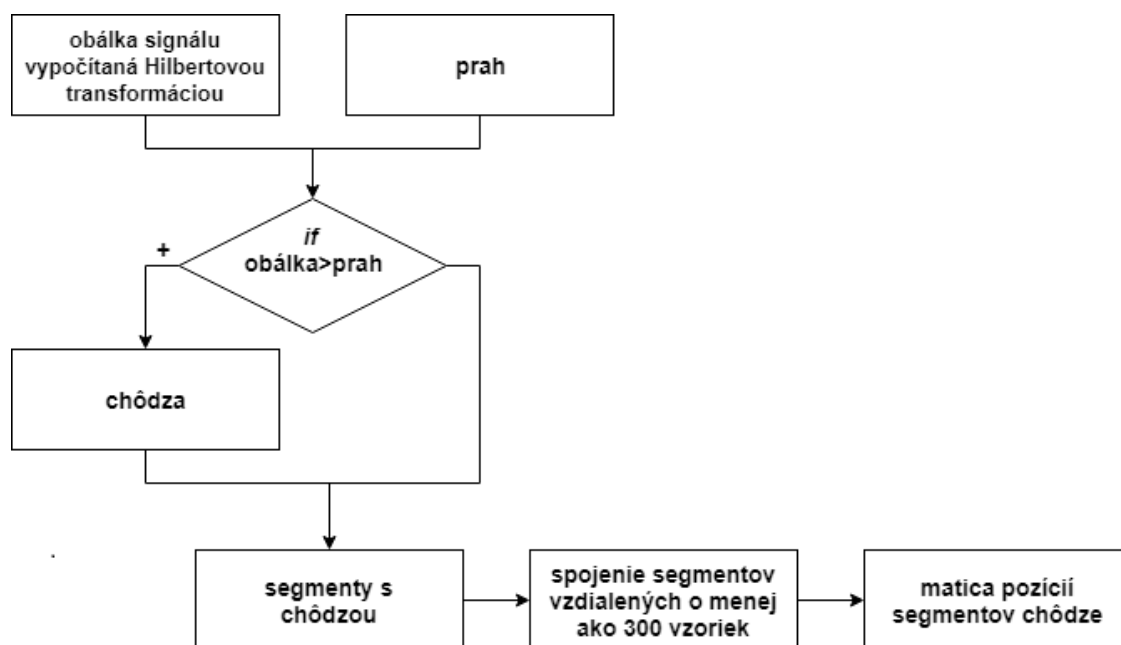
kde env_n je obálka signálu [24].

Chôdza je odlíšená použitím prahovej hodnoty, ktorá bola empiricky určená ako priemerná hodnota z obálky. Prvým krokom je nájdenie častí obálky, ktoré sú nad prahovou hodnotou. Ako je možné vidieť na obrázku 22, nad prahom je vždy len časť obálky v časti, kde je zrejмый výskyt chôdze, čiže jeden segment chôdze je rozsekaný na menšie. Pre nájdenie týchto častí sa použije funkcia *findpeaks*. Výstupom z tejto funkcie je vektor pozícií, na ktorých je hodnota obálky nad prahovou hodnotou. Do výslednej matice sa na prvú pozíciu

zapiše prvá hodnota tohto vektora, a na druhú pozíciu sa zapiše pozícia, ktorá je od nasledujúcej pozície vo vektore vzdialená o aspoň 300 vzoriek (tri sekundy), teda splňuje predpoklad, že je koncovou pozíciou segmentu chôdze, a prejde sa do ďalšieho riadku. Takto sa pokračuje až do posledného prvku vo vektore pozícií. Schému algoritmu je možné vidieť na obrázku 23.

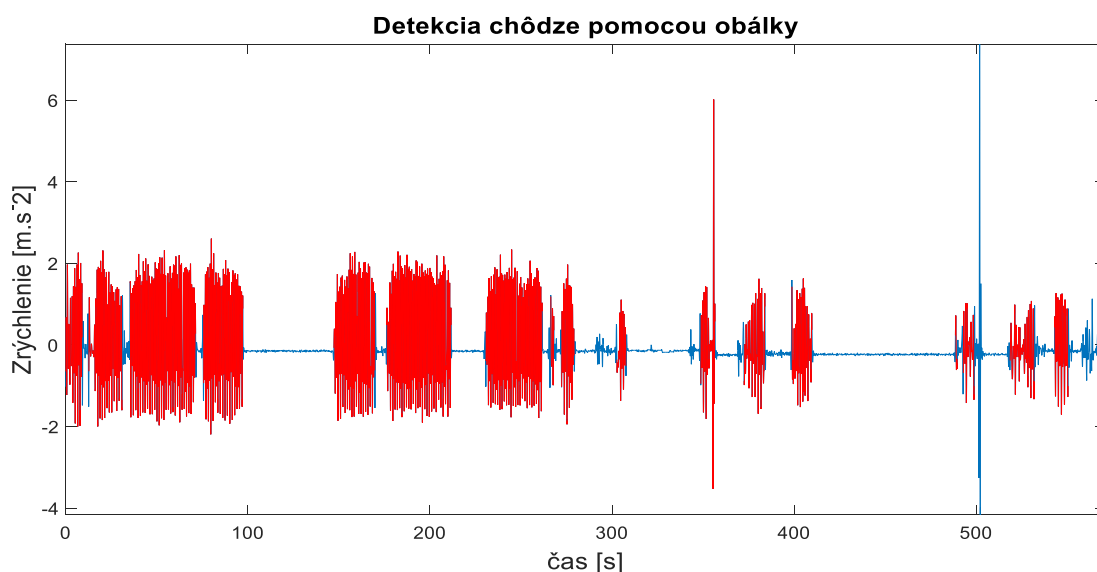


Obrázok 22: Obálka signálu



Obrázok 23: Schéma algoritmu na detekciu chôdze s využitím obálky signálu

Výsledkom je matica pozícií s dvomi stĺpcami, pričom v prvom stĺpci sú začiatky segmentov s chôdzou, a v druhom sú konce segmentov s chôdzou. Na obrázku 24 je vykreslená celková detekcia chôdze metódou obálky pomocou tejto matice.



Obrázok 24: Detekcia chôdze pomocou obálky signálu (chôdza – červená)


4.2 Prvá diferenciacia signálu

Keďže začiatok a koniec segmentu chôdze v signáli bežnej dennej aktivity nie je vždy dostatočne ostrý, dá sa na účel detekcie začiatku a konca segmentu s chôdzou využiť prvú diferenciaciu signálu. Vychádza z predpokladu, že extrémny v signáli prvej diferencie sú na mieste prechodu nulou v pôvodnom signáli. Prvá diferenciacia v diskretnom signáli sa vypočíta ako

$$d(n) = s(n) - s(n - 1) \quad (6)$$

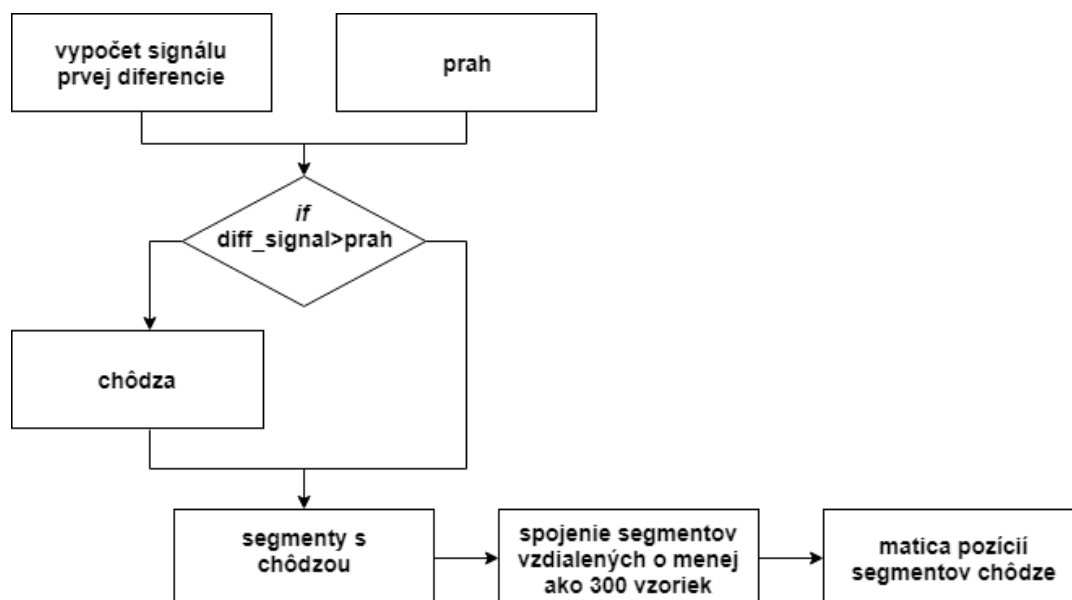
kde $d(n)$ je aktuálna vzorka prvej diferencie, $s(n)$ je aktuálna vzorka pôvodného signálu a $s(n-1)$ je predchádzajúca vzorka pôvodného signálu [24].

Na obrázku 25 je vykreslený signál bežnej aktivity spolu s jeho prvou diferenciou, pričom prvá diferenciacia má tvar skoro rovnej čiary pri žiadnej aktivite v signáli (a to aj pri jeho miernych výchyľkách), ale pri zrejmom začiatku chôdze sa jej hodnota začne zvyšovať.




Obrázok 25: Prvá diferenciacia signálu bežnej aktivity

Samotné využitie na detekciu začiatku, respektíve konca chôdze je také, že ak signál prvej diferencie prekročí prahovú hodnotu, ktorá bola empiricky určená ako 40 % smerodajnej odchýlky tohto signálu, tak sa zapíše pozícia, na ktorej bola prekročená táto hodnota, do prvého stĺpca matice. Do druhého stĺpca matice sa zapíše pozícia, kedy signál zase prekročí prahovú hodnotu, a teda ukončí daný segment chôdze. Ďalšie prekročenie, teda nový začiatok, sa zapíše do nového riadku matice, a pokračuje sa rovnako ako predtým až do konca signálu. Schému tohto algoritmu je možné vidieť na obrázku 26.



Obrázok 26: Schéma algoritmu na detekciu chôdze s využitím prvej diferencie

Výsledkom je teda matica s dvomi stĺpcami a riadkami, ktorých počet predstavuje počet segmentov chôdze v danom signáli. Ak je rozdiel pozícií v druhom stĺpci jedného riadku a prvom stĺpci nasledujúceho riadku menší alebo rovný ako 300 vzoriek, čo odpovedá trom sekundám, tak sa časti pôvodného signálu medzi týmito pozíciami zapíšu ako jeden segment chôdze. Na obrázku 27 je možné vidieť segmenty chôdze detegované touto metódou.



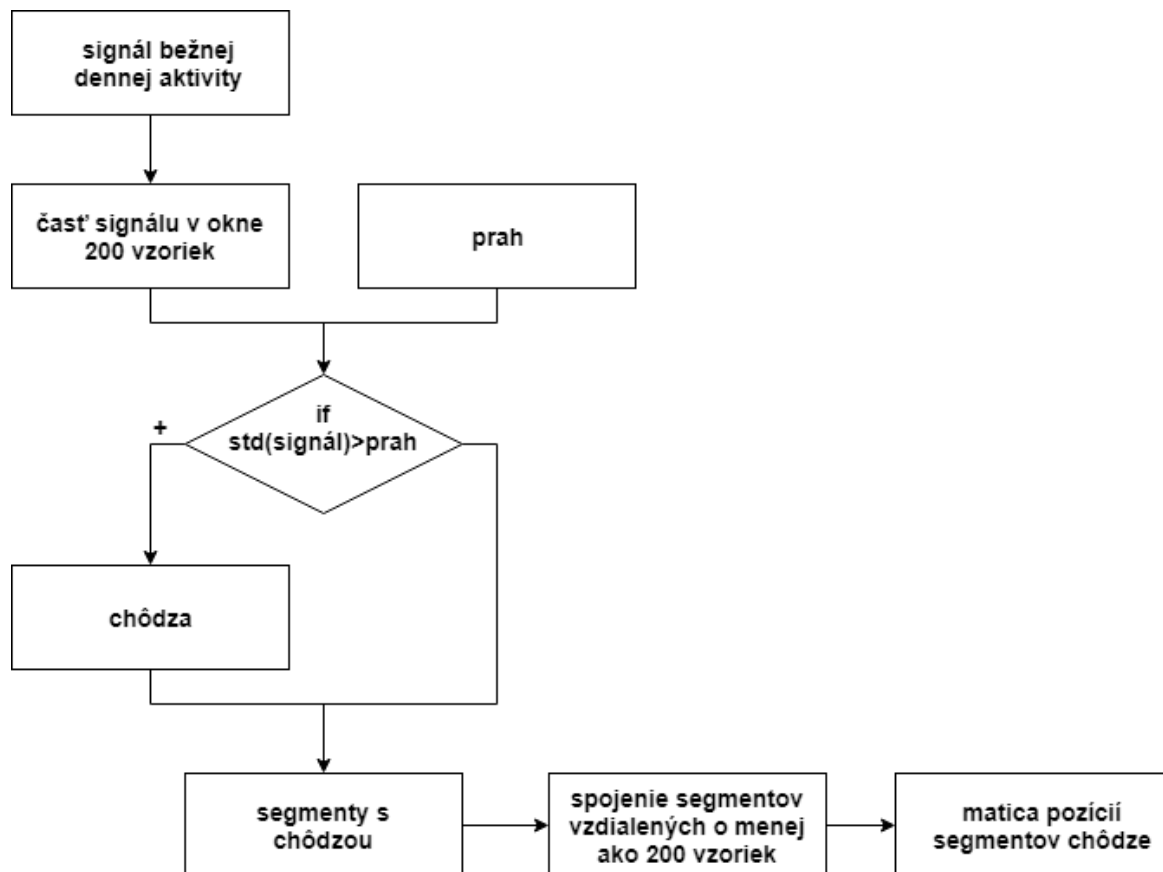
Obrázok 27: Detekcia chôdze pomocou prvej diferencie (chôdza - červená)

4.3 Smerodajná odchýlka

Ako posledná metóda sa osvedčil výpočet smerodajnej odchýlky časti signálu v pevnom okne. Ak smerodajná odchýlka časti signálu bežnej aktivity v okne 200 vzoriek prekročila prahovú hodnotu, zapísali sa okrajové pozície okna do pomocnej matice ako časti signálu, v ktorých sa nachádza chôdza. Prahová hodnota bola stanovená empiricky ako jedna polovica smerodajnej odchýlky zo vzorového signálu chôdze. Takto sa postupovalo po celej dĺžke signálu, pričom pri detegovanej chôdzi v okne sa zapísali okrajové pozície okna do nového riadku v pomocnej matici.

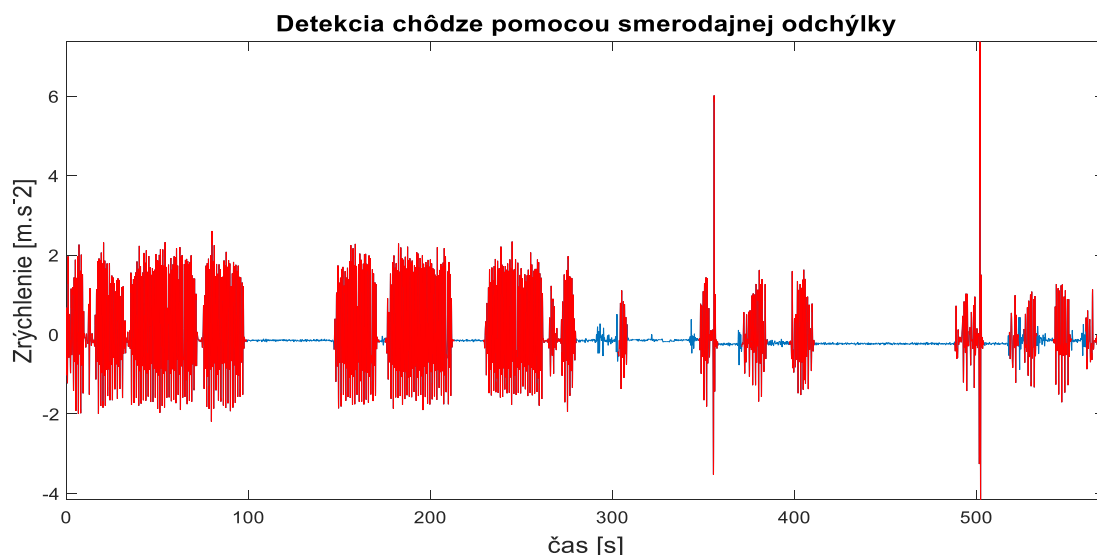
V dôsledku používania pevného okna je spravidla jeden segment chôdze rozdelený v pomocnej matici na časti s dĺžkou zhodnou s veľkosťou okna. Vo výslednej matici je na začiatku prvý riadok totožný s prvým riadkom pomocnej matice, ale v ďalšom priebehu je pozícia v druhom stĺpci prepisovaná. Pomocná matica je postupne prechádzaná po riadkoch, a ak je pozícia v prvom stĺpci v danom riadku nasledujúca za pozíciou v druhom stĺpci výslednej matice o menej ako 200 vzoriek, táto sa prepíše na pozíciu zapísanú v druhom stĺpci v aktuálnom riadku pomocnej matice. Takto sa pokračuje, až pokiaľ

vzdialenosť dvoch krajných pozícií nie je väčšia ako 200. Vtedy sa aktuálny riadok pomocnej matice zapíše do ďalšieho riadku výslednej matice a pokračuje sa tak isto ako v prípade prvého riadku výslednej matice až do posledného riadku pomocnej matice. Schému algoritmu je možné vidieť na obrázku 28.



Obrázok 28: Schéma algoritmu na detekciu chôdze s využitím smerodajnej odchýlky

Výsledná matica má opäť dva stĺpce pre počiatočné a koncové pozície segmentu s chôdzou, a počet riadkov sa zhoduje s počtom segmentov chôdze detegovaných touto metódou. Detekciu chôdze s využitím tejto metódy je možné vidieť na obrázku 29.



Obrázok 29: Detekcia chôdze pomocou smerodajnej odchýlky (chôdza – červená)

4.4 Výsledná detekcia chôdze

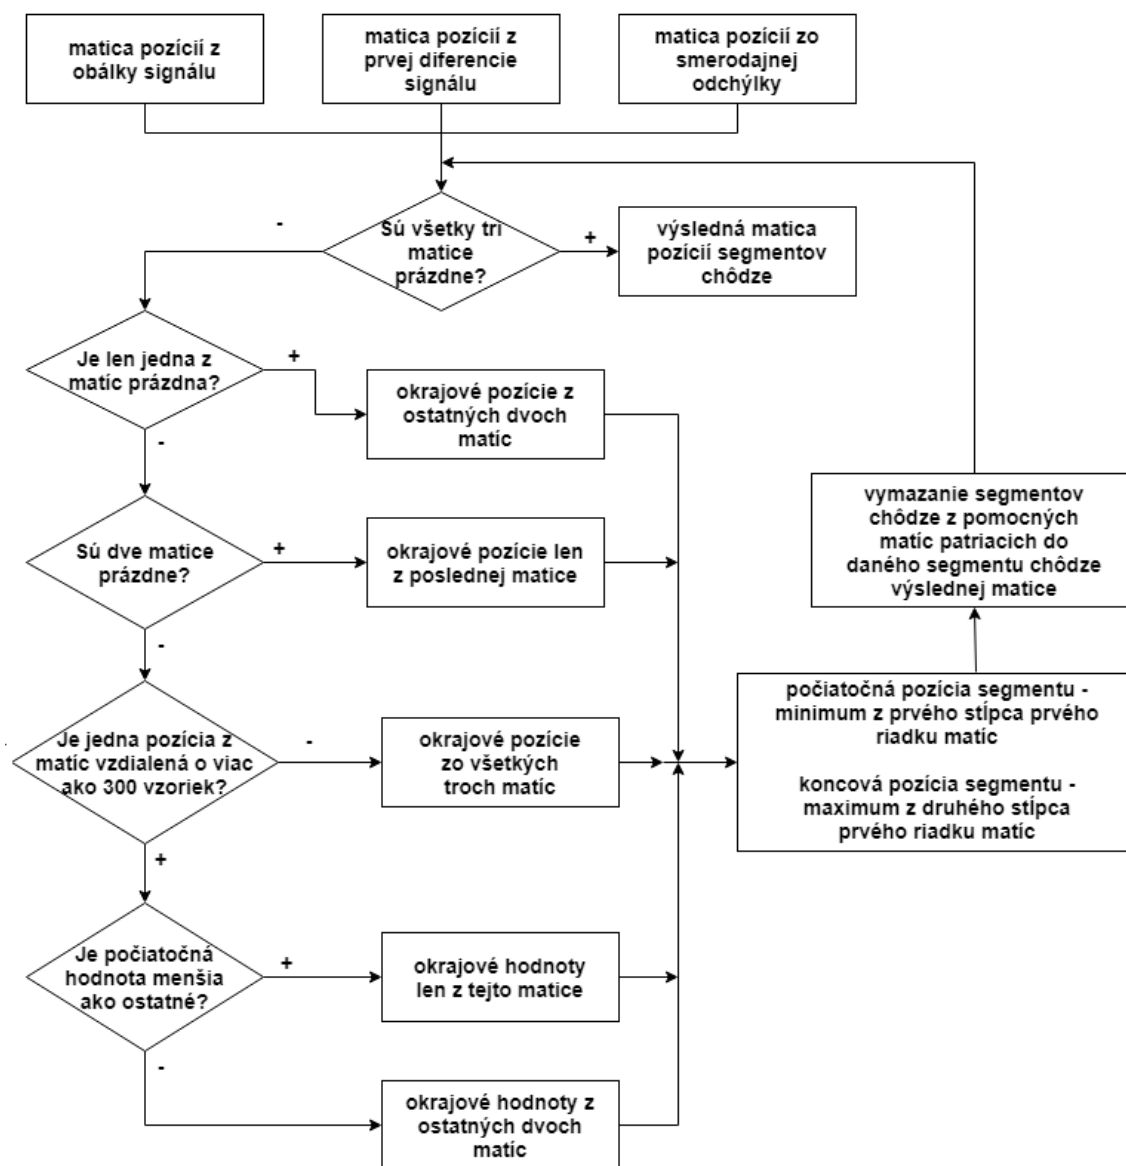
Výsledkom predchádzajúcich metód sú 3 matice, ktoré obsahujú začiatkové a koncové pozície, ktoré ohraničujú časti signálu bežnej aktivity, v ktorých sa nachádza chôdza. Tieto hraničné body sa u každej metódy líšia o pár vzoriek, prípadne jedna metóda deteguje chôdzu tam, kde ostatné nie, preto je potrebné tieto matice spojiť do jednej.

Každá matica má dva stĺpce – v prvom sú zaznamenané začiatky segmentov chôdze a v druhom konce segmentov. Porovnávajú sa pozície vo všetkých troch maticiach naraz. Ak sú počiatkové a koncové pozície približne rovnaké, tak sa do výslednej matice zapíše ako počiatková pozícia (do prvého stĺpca) najmenšia hodnota z prvého stĺpca zo všetkých matíc, a ako koncová pozícia (do druhého stĺpca) sa zapíše najväčšia hodnota z druhého stĺpca všetkých matíc. Po zapísaní sa zmažú pozície segmentov chôdze zo všetkých troch matíc, ktoré sa nachádzajú vnútri zapísaného intervalu, a taktiež pozície segmentov, ktoré začínajú uprostred intervalu, ale končia až za ním. V tomto prípade sa koncová pozícia segmentu vo výslednej matici prepíše na koncovú pozíciu tohto vyčnievajúceho segmentu.

Ak sú počiatkové a koncové pozície v jednej matici vzdialené od pozícií v ostatných maticiach o viac ako 300 vzoriek, znamená to, že buď detegovala daný segment chôdze len táto jedna matica, alebo naopak, táto matica daný segment nedetegovala. Ak sa počiatkové pozície v tejto matici nachádzajú pred počiatkovými pozíciami v ostatných maticiach, nastala prvá možnosť a do výslednej matice sa zapíšu pozície z tejto matice. Avšak, ak sa tieto pozície nachádzajú za koncovými pozíciami ostatných matíc, do výslednej matice sa


zapisujú počiatočné a koncové pozície spôsobom obdobným tomu, ktorý bol popísaný v predchádzajúcom odseku.

Keďže nie vždy majú všetky tri matice rovnaký počet riadkov, môže nastať situácia, že niektorá matica sa zmaže celá skôr ako ostatné. V tom prípade sa berú minimá a maximá len z matíc, ktoré nie sú prázdne. Ak ostane len posledná matica, ktorá nie je prázdna, pozície sa zapisujú len z nej. Schému algoritmu je možné vidieť na obrázku 30.



Obrázok 30: Schéma výsledného algoritmu na detekciu chôdze


Výsledná detekcia chôdze je zobrazená na obrázku 31.



Obrázok 31: Porovnanie metód na detekciu chôdze (chôdza - červená)

5 Výsledný algoritmus

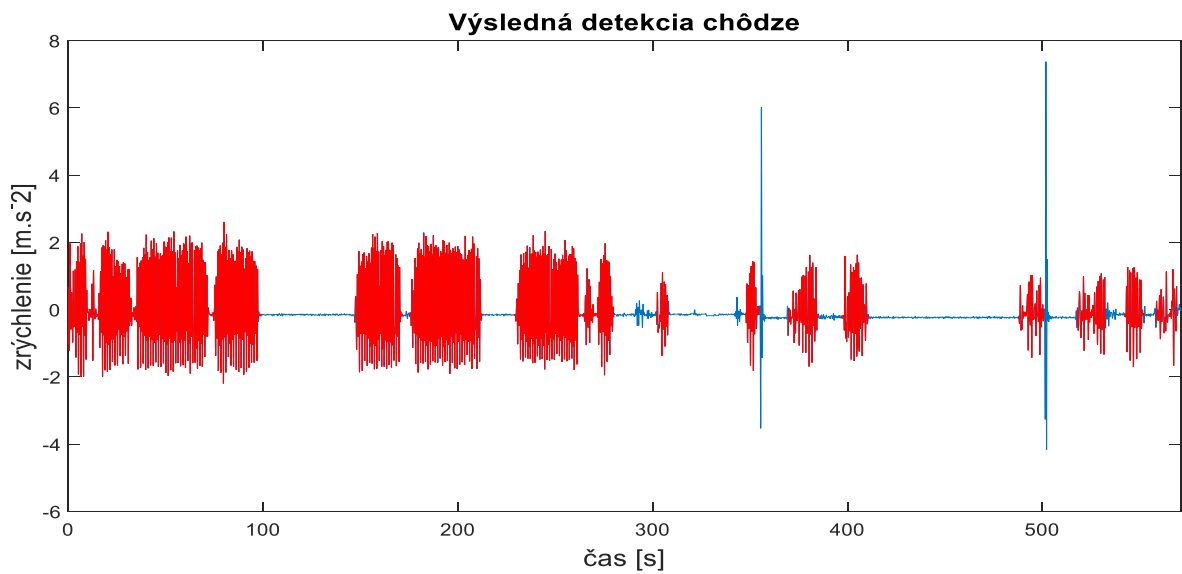
V predchádzajúcej kapitole bol popísaný algoritmus na detekciu chôdze. Avšak ako je zrejmé z obrázku 32, tento algoritmus označí za segmenty s chôdzou aj oblasti, v ktorých je zrejmé, že došlo k pádu.



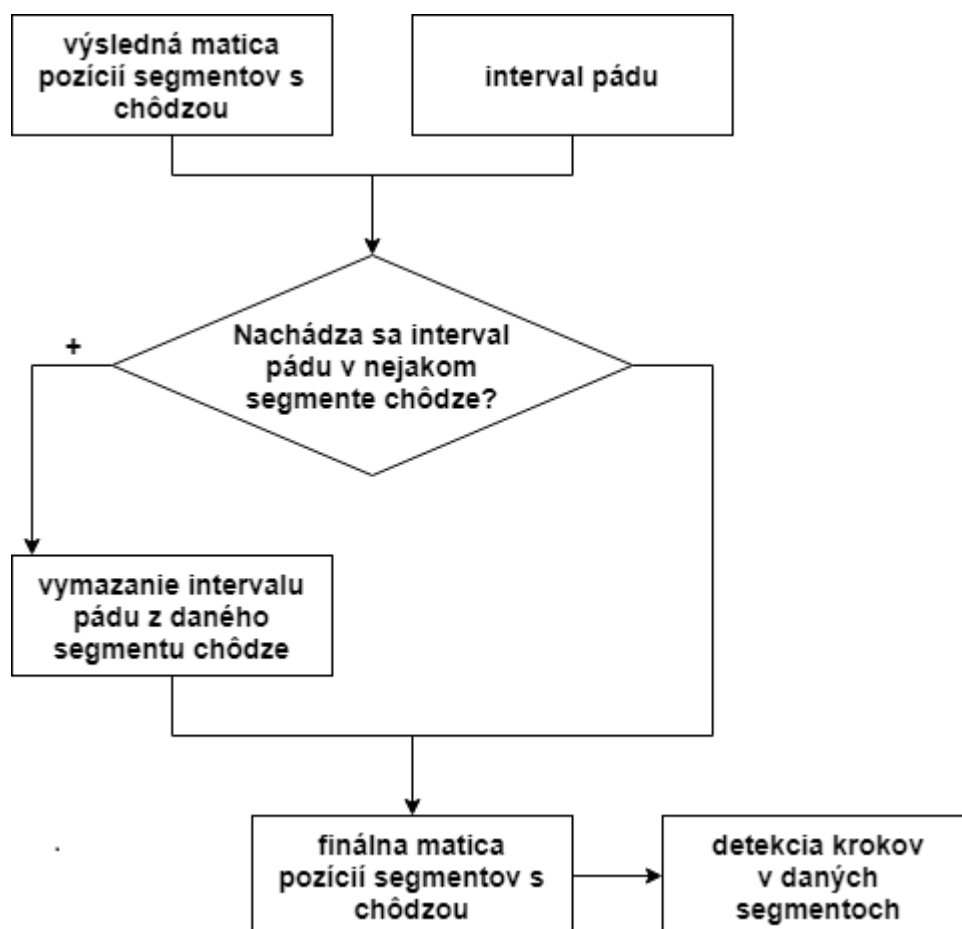
Obrázok 32: Detekcia chôdze vrátane pádu

Z tohto dôvodu je dôležité zaistiť, aby neboli v segmentoch s chôdzou zahrnuté aj pády, keďže tieto by mohli skresliť počet detegovaných krokov. Za začiatok pádu sa považuje bod, ktorý sa nachádza 1200 ms (120 vzoriek) pred detegovaným pádom, a za koniec sa považuje bod, ktorý sa nachádza 2500 ms (250 vzoriek) za detegovaným pádom [26]. Ak sa tento interval, alebo jeho časť, nachádza v detegovanej chôdzi, je potrebné ho zo segmentov chôdze vynechať.

V predchádzajúcej kapitole boli začiatky a konce častí s chôdzou v signáli bežnej aktivity uložené do matice. Ak sa v niektorom segmente nachádza začiatok alebo koniec intervalu pádu, táto časť sa z výslednej matice vynechá (obrázok 33). Schému výsledného algoritmu je možné vidieť na obrázku 34.




Obrázok 33: Detekcia chôdze po vynechaní intervalu s pádom



Obrázok 34: Výsledný algoritmus

Výsledná detekcia chôdze a pádu po použití všetkých algoritmov je vykreslená na obrázku 35.



Obrázok 35: Výsledná detekcia chôdze a pádu

6 Meranie

Snímanie signálov za účelom testovania navrhnutého algoritmu prebiehalo u 10 rôznych subjektov. Každý subjekt mal za úlohu nasnímať signál bežnej aktivity pomocou akcelerometru zabudovaného v smartfóne Huawei P9 Lite 2016, ktorý bol umiestnený v prednom vrecku nohavíc subjektu, a aplikácie Sense it so vzorkovacou frekvenciou 100 Hz, tak ako tomu bolo aj v prípade snímania dát za účelom vývoja algoritmu.

Samotné meranie prebiehalo v troch skupinách, pričom každá z nich mala trošku iné zadanie, čo má robiť. Všetky tri skupiny ale mali spoločný približný čas, počas ktorého malo meranie prebiehať – päť až desať minút. V prvej, najväčšej skupine s počtom piatich ľudí, sa náhodne striedala krátka chôdza s kľudom, a celé snímanie bolo ukončené simulovaným pádom. Výnimku tvorila jedna osoba, ktorá do priebehu merania zakomponovala okrem simulovaného pádu na konci ďalší pád počas merania. V druhej skupine s počtom troch ľudí sa striedala intenzívna, dlhá chôdza s krátkymi pauzami bez aktivity, a snímanie bolo taktiež ukončené simulovaným pádom. Tretia skupina s počtom dvoch ľudí mala za úlohu počas snímania ísť dole z kopca a následne ho zase vyliezť, a následne striedať pokojové činnosti, akými je státie či sedenie, s chôdzou po rovine. V tejto skupine sa simulovaný pád nenachádzal na konci snímania, ale uprostred.

Keďže každá skupina mala iné zadanie, nasnímané signály sa medzi skupinami líšia či už vzhľadovo, alebo samotným počtom krokov, pričom sa najviac odlišujú signály z druhej skupiny od ostatných.

Dĺžky jednotlivých signálov v počte vzoriek a v minútach sú uvedené v tabuľke 1.

skupina	1				
subjekt	1	2	3	4	5
Dĺžka signálu [-]	39699	46503	49139	57120	30783
Dĺžka signálu [min]	6,61	7,75	8,19	9,52	5,13
skupina	2			3	
subjekt	6	7	8	9	10
Dĺžka signálu [-]	50595	56728	51880	35949	30389
Dĺžka signálu [min]	8,43	9,45	8,65	5,99	5,06

Tabuľka 1: Dĺžky signálov

7 Výsledky

Ako bolo spomenuté v predchádzajúcej kapitole, celkovo bolo nameraných desať signálov dennej aktivity desiatimi rôznymi subjektami v troch skupinách. V každom nameranom signáli bola detegovaná chôdza, v nej počet krokov a pád.

Správnosť detekcie chôdze je možné vyjadriť pomocou štatistického ukazovateľa senzitivita, ktorý vyjadruje pravdepodobnosť, že bola detegovaná chôdza, ak sa naozaj v signáli nachádzala. Senzitivitu je možné vyjadriť ako

$$\text{Senzitivita} = \frac{SP}{SP+FN} \times 100\%, \quad (7)$$

kde SP označuje správne detegované segmenty chôdze a FN označuje falošne negatívne, teda nedetegované segmenty chôdze [24]. Výsledky je možné vidieť v tabuľke 2.

Skupina	Subjekt	SP	FN	Senzitivita [%]
1	1	6	0	100
1	2	11	1	91.67
1	3	10	1	90.91
1	4	13	0	100
1	5	6	1	85.71
2	6	3	0	100
2	7	4	0	100
2	8	4	1	80
3	9	5	0	100
3	10	7	0	100
	Priemerná presnosť			94,83

Tabuľka 2: Presnosť detekcie chôdze

V tabuľkách 3 a 4 je možné vidieť počty naozaj prejdenných krokov, počty krokov detegovaných pomocou jednotlivých metód, a absolútne odchýlky jednotlivých metód od skutočnosti a odchýlky v percentách, ktoré boli vypočítané podľa rovnice (8).

$$\text{odchýlka} = \left| \frac{\text{počet detegovaných krokov} \times 100}{\text{počet skutočne prejdenných krokov}} - 100 \right| \quad (8)$$

Skupina	Subjekt	Skutočný počet krokov	Počet detegovaných krokov	Odchýlka [počet krokov]	Odchýlka [%]
1	1	267	259	8	2,9963
1	2	431	420	11	2,5522
1	3	446	437	9	2,0179
1	4	364	354	10	2,7472
1	5	368	348	20	5,4348
2	6	853	850	3	0,3517
2	7	816	814	2	0,2451
2	8	842	866	24	2,8504
3	9	362	352	10	2,7624
3	10	299	290	9	3,0100
	Priemerná odchýlka			10,6	2,4969

Tabuľka 3: Výsledky detekcie krokov – metóda vyhľadávania peakov

Skupina	Subjekt	Skutočný počet krokov	Počet detegovaných krokov	Odchýlka [počet krokov]	Odchýlka [%]
1	1	267	236	31	11,6105
1	2	431	418	13	3,0162
1	3	446	422	24	5,3812
1	4	364	331	33	9,0659
1	5	368	351	17	4,6196
2	6	853	854	1	0,1172
2	7	816	702	114	13,9706
2	8	842	715	127	15,0831
3	9	362	374	12	3,3149
3	10	299	270	29	9,6990
	Priemerná odchýlka			40,1	7,5878

Tabuľka 4: Výsledky detekcie krokov - metóda prispôbeného filtra

Ako už bolo spomenuté vyššie, každý signál obsahoval aspoň jeden nasimulovaný pád. Výsledky detekcie je možné vidieť v tabuľke 5. Na vyhodnotenie týchto výsledkov boli využité dva štatistické ukazovatele - senzitivita a pozitívna prediktivita.

Senzitivita vyjadruje pravdepodobnosť pozitívnej detekcie, ak v skutočnosti prebehol pád, ktorá sa vypočíta pomocou vzorca

$$\text{Senzitivita} = \frac{SP}{SP+FN} \times 100\%, \quad (7)$$

kde SP označuje správne detegované pády a FN označuje falošne negatívne, teda nedetegované pády [24].

Pozitívna prediktivita vyjadruje pravdepodobnosť správne detegovaného pádu pri pozitívnej detekcii, ktorá sa vypočíta pomocou vzorca

$$\text{Pozitívna prediktivita} = \frac{SP}{SP+FP} \times 100, \quad (9)$$

kde SP označuje správne detegované pády a FP falošne pozitívne detegované pády, teda pády, ktoré sa v skutočnosti nestali, ale napriek tomu boli detegované [24].

Skupina	Subjekt	Počet nasimulovaných pádov	Počet detegovaných pádov	Senzitivita [%]	Prediktivita [%]
1	1	1	1	100	100
1	2	1	1	100	100
1	3	1	1	100	100
1	4	2	2	100	100
1	5	1	1	100	100
2	6	1	1	100	100
2	7	1	1	100	100
2	8	1	2	100	50
3	9	1	1	100	100
3	10	1	2	100	50
	Priemerná hodnota			100	90

Tabuľka 5: Výsledky detekcie pádu

Diskusia

V tejto práci boli navrhnuté tri druhy algoritmov – na detekciu chôdze v signáli bežnej dennej aktivity, na detekciu krokov a detekciu pádu. Všetky algoritmy boli implementované v prostredí Matlab.

Na detekciu chôdze boli použité algoritmy založené na troch rozličných metódach – detekcia s využitím obálky signálu, detekcia s využitím prvej diferencie a detekcia s využitím smerodajnej odchýlky – a následnom prahovaní. Keďže každá metóda zvyčajne detegovala rozličné úseky chôdze, v rámci algoritmu boli spojené do jedného detektoru, ktorého priemerná senzitivita, teda pravdepodobnosť detekcie všetkých častí s chôdzou, bola 94,83 %. V porovnaní s algoritmi od iných autorov, ktoré dosahovali presnosti uvedené v tabuľke 6, vykazuje algoritmus tejto práce pomerne vysokú úspešnosť detekcie vzhľadom na jednoduchosť implementovaných metód.

Autori algoritmu	Presnosť
Cvetković, Szeklicki, Janko, Lutomski, Luštrek [27]	91 %
Hsu, Yang, Chang, Lai [28]	90,7 %
Álvarez de la Concepción, Soria Morillo, Gonzalez-Abril, Ortega Ramírez – metóda Ameva	98,77 %
Álvarez de la Concepción, Soria Morillo, Gonzalez-Abril, Ortega Ramírez – metóda RNA [29]	97,93 %

Tabuľka 6: Presnosti detekcie chôdze od iných autorov

Po detekcii chôdze nasledovala detekcia pádu. Pád bol detegovaný len jedným algoritmom, ktorý je založený na využití dvoch prahových hodnôt, jednej zápornej a druhej kladnej, pričom sa hľadá postupnosť dvoch extrémov – po sebe bezprostredne nasledujúcich hodnôt prekračujúcich obe prahové hodnoty. Pre optimalizáciu bolo zavedené porovnanie päťsekundového okna pred a za detegovaným pádom. V tomto okne sa vypočíta smerodajná odchýlka a priemerná hodnota, a ak je jeden z týchto ukazovateľov väčší v okne pred detegovaným pádom ako v okne za ním, je nadetegovaný pád správny, ak nie, je falošný. Senzitivita tohto algoritmu je 100 %, teda každý pád bol zachytený algoritmom, avšak pozitívna prediktivita je 90 %, čo znamená, že pád zachytený algoritmom naozaj nastal s pravdepodobnosťou „len“ 90 %. Úspešnosť tohto detektoru pádu z hľadiska použitia pre rôzne aplikácie je dobrá, keďže každý pád, ktorý sa v skutočnosti stal, bol detegovaný, aj keď sa niekedy detegujú ako pád aj iné aktivity. Algoritmy od ostatných autorov vykazovali úspešnosti detekcie pádu uvedené v tabuľke 7. Keďže v rámci

algoritmu tejto práce boli implementované dve prahové hodnoty a celkovo tri podmienky, ktoré musí detegovaný pád spĺňať, je jeho úspešnosť porovnateľná, prípadne lepšia ako v prípade iných algoritmov. Ďalej bol vypočítaný interval pádu. Ak tento interval zasahoval do častí s detegovanou chôdzou, odstránil sa z detegovanej chôdze kvôli skresľovaniu následnej detekcie a počítania krokov.

Autori algoritmu	Úspešnosť
Ryu, Moon – pád na brucho [16]	95 %
Ryu, Moon – pád na chrbát [16]	98 %
Nguyen, Mirza, Naeem, Baig [20]	93,18 %
Rungnapaken, Chintakovid, Wuttidittachotti [25]	100 %

Tabuľka 7: Úspešnosť algoritmov detekcie pádu od iných autorov

Nakoniec nasledovala detekcia krokov v častiach signálu, v ktorých bola detegovaná chôdza. Na tento účel boli použité dve metódy – metóda vyhľadávania peakov a metóda s využitím prispôbeného filtra. Pri prvej metóde bola vypočítaná priemerná odchýlka od skutočného počtu krokov 2,4969 %, čo predstavuje 10,6 kroku a pri druhej metóde 7,5878 %, čo predstavuje 40,1 kroku. Na základe výpočtov je teda zrejmé, že metóda vyhľadávania peakov bola oveľa presnejšia. Aj v porovnaní s priemernými odchýlkami algoritmov ostatných autorov uvedených v tabuľke 8 vykazuje táto metóda porovnateľné výsledky, zatiaľ čo metóda prispôbeného filtra má priemernú odchýlku o približne 4 až 7 percent vyššiu. Tieto odchýlky boli spôsobené nedokonalou detekciou úsekov s chôdzou, v rámci ktorej neboli vôbec detegované niektoré úseky, ale kroky v týchto segmentoch boli započítané do počtu skutočných krokov. Ďalej počet skutočných krokov mohol byť skreslený ľudskou chybou, keďže tieto kroky boli rátané manuálne.

Autori algoritmu	Odchýlka
Cho Y., Cho H., Kyung [18]	0,76 %
Herrera, Trujillo, Alvarez, Sierra [23]	3 %
Park S.Y., Heo, Park Ch. G.	3,88 %

Tabuľka 8: Odchýlky algoritmov detekcie krokov od iných autorov

Ako bolo spomínané v podkapitole 1.4.1, väčšina už vymyslených a otestovaných algoritmov na detekciu krokov využíva metódu vyhľadávania lokálnych maxím, metódu prechodov nulou alebo metódu korelácie. Všetky tieto metódy boli implementované v rámci výsledného algoritmu, keďže metóda vyhľadávania peakov využíva okrem vyhľadávania lokálnych maxím sčasti aj prechody nulou pri vyhľadávaní lokálnych miním,

ktoré predchádzajú a nadchádzajú maximum, a metóda korelácie je použitá v metóde prispôbeného filtra, keďže v tejto metóde ide o detekciu pomocou korelácie akcelerometrického signálu a vzoru kroku obráteného v čase. Výhoda výsledného algoritmu tejto práce je to, že v rámci prvej metódy sú použité dva už existujúce algoritmy vykazujúce dobrú úspešnosť, a tým sa teda zminimalizovala chybovosť metódy. Nevýhodou je, že na detekciu a počítanie krokov sú použité dve metódy, pričom presnosť každej z nich závisí od typu signálu – niekedy je presnejšia metóda vyhľadávania peakov a inokedy zase metóda prispôbeného filtra.

Čo sa týka detekcie pádu, v podkapitole 1.4.2 boli taktiež spomenuté tri druhy už vymyslených spôsobov detekcie založené na rôznych typoch senzorov. V tejto práci bola využitá metóda založená na pohybovom senzore (akcelerometer) a na prahových hodnotách. Na rozdiel od iných metód využívajúcich napríklad akustické senzory (mikrofón), je niekedy ťažké odlíšiť pád od ostatných aktivít, ktoré majú podobný tvar v akcelerometrickom signáli, napríklad výskoky. Tie by sa pomocou akustických senzorov nezaznamenali ako pád, keďže s vysokou pravdepodobnosťou pri nich nedôjde k buchnutiu, ktoré často sprevádza pád. Ďalej v porovnaní s metódami, ktoré používajú rozpoznávanie vzorov pomocou strojového učenia, je algoritmus používaný v tejto práci menej náročný na výpočty a pamäť, čo je jeho hlavnou výhodou. Ďalšou výhodou je využitie akcelerometra, ktorý sa nachádza v každom inteligentnom zariadení, či už je to smartfón alebo fitness náramok. Nevýhodou je občas nesprávne vyhodnotenie inej aktivity ako pádu.

Záver

V tejto bakalárskej práci boli preskúmané možnosti snímania ľudských aktivít pomocou inerciálnych senzorov zabudovaných v inteligentných zariadeniach a následného spracovania a rozoznávania rôznych aktivít. Práca je zameraná hlavne na detekciu chôdze, pádu a krokov zo signálu získaného pomocou akcelerometru v smartfóne.

Detekcia chôdze zo signálu bežnej dennej aktivity bola prevedená pomocou smerodajnej odchýlky signálu, obálky signálu a prvej diferencie signálu s priemernou presnosťou 94,83 %. Následne bol detegovaný pád pomocou prahových hodnôt, pričom všetky simulované pády boli zachytené algoritmom, a v prípade pozitívnej detekcie pádu šlo o simulovaný pád s pravdepodobnosťou 90 %. Nakoniec sa v častiach s detegovanou chôdzou počítali kroky dvomi metódami – vyhľadávaním peakov a prispôbenou filtráciou. Priemerná odchýlka prvej metódy bola 2,4969 % a druhej metódy 7,5878 %. Výsledný algoritmus považujem za úspešný v porovnaní s algoritmi od ostatných autorov.

Hlavný prínos tejto práce je možné využitie v aplikáciách pre smartfóny alebo iné inteligentné zariadenia pre ľudí, ktorých zaujíma počet prejdých krokov za istý časový interval, alebo pre ľudí, ktorí trpia rôznymi ochoreniami, pri ktorých by mohlo dôjsť k pádu, napríklad pri epileptických či iných záchvatoch. Ďalšie využitie po menších úpravách by mohlo byť pre špeciálne zariadenia obsahujúce akcelerometer pre seniorov, ktorí väčšinou nevlastnia smartfón alebo inteligentné hodinky, ale aj tak sú náchylní na náhly pád z rôznych zdravotných príčin alebo nečinnosť kvôli problémom s pohyblivosťou. Pomocou týchto zariadení by sa snímal jednak počet prejdých krokov za deň, ktorý by musel dosiahnuť istý počet, aby sa predišlo nečinnosti, a taktiež prípadný pád, pri ktorom by sa po správnej detekcii zavolala pomoc.

V budúcnosti by mohla byť práca rozšírená o odlíšenie viacerých aktivít, nielen chôdze, napríklad o rozlíšenie behu alebo výskokov. Ďalej by mohol byť algoritmus na detekciu pádu rozšírený o rozlíšenie smeru, do ktorého človek padol, teda či padol dopredu, dozadu alebo do boku. V algoritme na detekciu a počítanie krokov by mohli byť obe metódy spojené do jednej optimalizovanej, pričom je možné, že by sa zmenšila odchýlka od skutočného počtu krokov.

Literatúra

- [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* [online]. 2017, **47**(7), 1303-1315 [cit. 2018-12-25]. DOI: 10.1007/s40279-016-0663-1. ISSN 0112-1642. Dostupné z: <http://link.springer.com/10.1007/s40279-016-0663-1>
- [2] Physical Activity and Adults. *WHO* [online]. [cit. 2018-12-27]. Dostupné z: https://www.who.int/dietphysicalactivity/factsheet_adults/en/
- [3] Falls prevention facts. *NCOA* [online]. [cit. 2018-12-27]. Dostupné z: <https://www.ncoa.org/news/resources-for-reporters/get-the-facts/falls-prevention-facts/>
- [4] XU, Wenyao, Mi ZHANG, A. A. SAWCHUK a M. SARRAFZADEH. Robust Human Activity and Sensor Location Corecognition via Sparse Signal Representation. *IEEE Transactions on Biomedical Engineering* [online]. 2012, **59**(11), 3169-3176 [cit. 2018-11-23]. DOI: 10.1109/TBME.2012.2211355. ISSN 0018-9294. Dostupné z: <http://ieeexplore.ieee.org/document/6259845/>
- [5] PASSARO, Vittorio M. N., Antonello CUCCOVILLO, Lorenzo VAIANI, Martino DE CARLO a Carlo Edoardo CAMPANELLA. Gyroscope Technology and Applications: A Review in the Industrial Perspective. *Sensors* [online]. 2017, **17**(10) [cit. 2018-11-23]. DOI: 10.3390/s17102284. ISSN 1424-8220. Dostupné z: <http://www.mdpi.com/1424-8220/17/10/2284>
- [6] SCHIRMER Maximilian a Hagen HOPFNER. Smartphone Hardware Sensors. Dostupné z: <https://www.uni-weimar.de/kunst-und-gestaltung/wiki/images/Zeitmaschinen-smartphonesensors.pdf>
- [7] WATSON, Jeff. MEMS Gyroscope Provides Precision Inertial Sensing in Harsh, High Temperature Environments. In: *Analog.com* [online]. [cit. 2018-11-23]. Dostupné z: <https://www.analog.com/en/technical-articles/mems-gyroscope-provides-precision-inertial-sensing.html>
- [8] LU, Yu-Sheng, Hsuan-Wen WANG a Sheng-Hao LIU. An integrated accelerometer for dynamic motion systems. *Measurement* [online]. 2018, **125**, 471-475 [cit. 2018-11-23]. DOI: 10.1016/j.measurement.2018.05.019. ISSN 02632241. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0263224118303993>
- [9] AYDEMIR, Akin, Yunus TERZIOGLU a Tayfun AKIN. A new design and a fabrication approach to realize a high performance three axes capacitive MEMS accelerometer. *Sensors and Actuators A: Physical* [online]. 2016, **244**, 324-333 [cit. 2018-11-24]. DOI: 10.1016/j.sna.2016.04.007. ISSN 09244247. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0924424716301522>
- [10] *Instrumentation Today* [online]. In: . [cit. 2018-01-26]. Dostupné z: <http://www.instrumentationtoday.com/mems-accelerometer/2011/08/>
- [11] Accelerometer. *Mathworks* [online]. In: . [cit. 2018-12-26]. Dostupné z: <https://in.mathworks.com/help/supportpkg/android/ref/accelerometer.html>

- [12] Apple Watch Series 4 [online]. [cit. 2018-12-25]. Dostupné z: <https://www.apple.com/lae/apple-watch-series-4/health/>
- [13] Apple Watch Series 4 [online]. In: . [cit. 2018-12-26]. Dostupné z: <https://support.apple.com/en-au/HT204666>
- [14] Axivity AX3 [online]. [cit. 2018-12-25]. Dostupné z <https://axivity.com/userguides/ax3/settings/#memory>
- [15] BYLEMANS, Inge, Maarten WEYN a Martin KLEPAL. Mobile Phone-Based Displacement Estimation for Opportunistic Localisation Systems. *2009 Third International Conference on Mobile Ubiquitous Computing, Systems, Services and Technologies* [online]. IEEE, 2009, 2009, , 113-118 [cit. 2018-11-24]. DOI: 10.1109/UBICOMM.2009.23. ISBN 978-1-4244-5083-1. Dostupné z: <http://ieeexplore.ieee.org/document/5361667/>
- [16] RYU, Jeong T. a Byung H. MOON. Fall Detection Algorithm based on Peaks of Voltage Measurements from the Accelerometer. *Indian Journal of Science and Technology* [online]. 2016, 9(45) [cit. 2019-04-20]. DOI: 10.17485/ijst/2016/v9i45/106768. ISSN 0974-5645. Dostupné z: <http://www.indjst.org/index.php/indjst/article/view/106768>
- [17] CHUANG, Fang-Chen, Jeen-Shing WANG, Ya-Ting YANG a Tzu-Ping KAO. A wearable activity sensor system and its physical activity classification scheme. *The 2012 International Joint Conference on Neural Networks (IJCNN)* [online]. IEEE, 2012, 2012, , 1-6 [cit. 2018-11-23]. DOI: 10.1109/IJCNN.2012.6252581. ISBN 978-1-4673-1490-9. Dostupné z: <http://ieeexplore.ieee.org/document/6252581/>
- [18] CHO, Yunhoon, Hyuntae CHO a Chong-Min KYUNG. Design and Implementation of Practical Step Detection Algorithm for Wrist-worn Devices. *IEEE Sensors Journal* [online]. , 1-1 [cit. 2018-12-31]. DOI: 10.1109/JSEN.2016.2603163. ISSN 1530-437X. Dostupné z: <http://ieeexplore.ieee.org/document/7552572/>
- [19] PIPANMAEKAPORN, Luepol, Puritud WICHINAWAKUL a Suwatchai KAMOLSANTIROJ. Mining Acceleration Data for Smartphone-based Fall Detection. *2018 10th International Conference on Knowledge and Smart Technology (KST)* [online]. IEEE, 2018, 2018, , 74-79 [cit. 2018-11-24]. DOI: 10.1109/KST.2018.8426201. ISBN 978-1-5386-4015-9. Dostupné z: <https://ieeexplore.ieee.org/document/8426201/>
- [20] NGUYEN, Hoa, Farhaan MIRZA, M. Asif NAEEM a Mirza Mansoor BAIG. Detecting Falls Using a Wearable Accelerometer Motion Sensor. *Proceedings of the 14th EAI International Conference on Mobile and Ubiquitous Systems Computing Networking and Services* [online]. New York, New York, USA: ACM Press, 2017, 2017, , 422-431 [cit. 2018-12-31]. DOI: 10.1145/3144457.3144484. ISBN 9781450353687. ISSN 1530-437X. Dostupné z: <http://dl.acm.org/citation.cfm?doid=3144457.3144484>
- [21] JAN, Jiří. *Číslicové zpracování a analýza signálů: stručné skriptum*. Brno: Vysoké učení technické v Brně, 2010. ISBN 978-80-214-4018-0.

- [22] ANTONSSON, Erik K. a Robert W. MANN. The frequency content of gait. *Journal of Biomechanics* [online]. 1985, 18(1), 39-47 [cit. 2017-11-20]. DOI:10.1016/0021-9290(85)90043-0. ISSN 00219290.
- [23] HERRERA, Edith Pulido, Yeni TRUJILLO, Roberth ALVAREZ a Daniel SIERRA. *Sampling Frequency for Step Detection Based on Smartphone Accelerometry* [online]. IEEE, 2017, 2017, , 409-413 [cit. 2018-11-24]. DOI: 10.1109/ISPAN-FCST-ISCC.2017.89. ISBN 978-1-5386-0840-1. Dostupné z: <http://ieeexplore.ieee.org/document/8121805/>
- [24] KOZUMPLÍK, J.: *Analýza biologických signálů*. Elektronická skripta UBMI FEKT VUT v Brně, 2012.
- [25] RUNGNAPAKAN, Traitot, Thippaya CHINTAKOVID a Pongpisit WUTTIDITTACHOTTI. *Proceedings of the 4th International Conference on Human-Computer Interaction and User Experience in Indonesia, CHuXiD '18 - CHuXiD '18* [online]. New York, New York, USA: ACM Press, 2018, 2018, , 49-53 [cit. 2018-12-26]. DOI: 10.1145/3205946.3205953. ISBN 9781450364294. Dostupné z: <http://dl.acm.org/citation.cfm?doid=3205946.3205953>
- [26] KHOJASTEH, Samad, José VILLAR, Camelia CHIRA, Victor GONZÁLEZ a Enrique DE LA CAL. Improving Fall Detection Using an On-Wrist Wearable Accelerometer. *Sensors* [online]. 2018, 18(5) [cit. 2019-04-22]. DOI: 10.3390/s18051350. ISSN 1424-8220. Dostupné z: <http://www.mdpi.com/1424-8220/18/5/1350>
- [27] CVETKOVIĆ, Božidara, Robert SZEKLICKI, Vito JANKO, Przemyslaw LUTOMSKI a Mitja LUŠTREK. Real-time activity monitoring with a wristband and a smartphone. *Information Fusion* [online]. 2018, 43, 77-93 [cit. 2019-05-22]. DOI: 10.1016/j.inffus.2017.05.004. ISSN 15662535. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1566253517303421>
- [28] HSU, Yu-Liang, Shih-Chin YANG, Hsing-Cheng CHANG a Hung-Che LAI. Human Daily and Sport Activity Recognition Using a Wearable Inertial Sensor Network. *IEEE Access* [online]. 2018, 6, 31715-31728 [cit. 2019-05-22]. DOI: 10.1109/ACCESS.2018.2839766. ISSN 2169-3536. Dostupné z: <https://ieeexplore.ieee.org/document/8362913/>
- [29] ÁLVAREZ DE LA CONCEPCIÓN, M.A., L.M. SORIA MORILLO, L. GONZALEZ-ABRIL a J.A. ORTEGA RAMÍREZ. Discrete techniques applied to low-energy mobile human activity recognition. A new approach. *Expert Systems with Applications* [online]. 2014, 41(14), 6138-6146 [cit. 2019-05-22]. DOI: 10.1016/j.eswa.2014.04.018. ISSN 09574174. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0957417414002152>