

**UNIVERZITA PAVLA JOZEFA ŠAFÁRIKA V KOŠICIACH
PRÍRODOVEDECKÁ FAKULTA**

**DETEKCIA POHYBU V ŠPECIFICKÝCH INDOOR
PROSTREDIACH S VYUŽITÍM SENZOROV
SMARTFÓNU**

Bakalárska práca

2017

Slavomír Slovenkai

**UNIVERZITA PAVLA JOZEFA ŠAFÁRIKA V KOŠICIACH
PRÍRODOVEDECKÁ FAKULTA**

**DETEKCIA POHYBU V ŠPECIFICKÝCH INDOOR
PROSTREDIACH S VYUŽITÍM SENZOROV
SMARTFÓNU**

Bakalárska práca

Študijný program: Informatika
Študijný odbor: 9.2.1. Informatika
Školiace pracovisko: Ústav informatiky
Vedúci práce: Mgr. Miroslav Opiela

Košice 2017

Slavomír Slovenkai

Pod'akovanie

Rád by som pod'akoval môjmu školiteľovi Mgr. Mirsolavu Opielovi za odborné vedenie a konštruktívne pripomienky počas tvorby tejto práce.

Abstrakt

Práca sa zaobrá detekciou pohybu v špecifickom indoor prostredí s využitím senzorov smartfónu za účelom určenia zmeny poschodia v budovách bez nutnosti vytvorenia dodatočnej infraštruktúry. Z dostupných senzorov, ktoré sú ponúkané smartfónmi, bol využitý najmä akcelerometer, ktorý sníma zrýchlenie pôsobiace na zariadenie a je dostupný vo väčšine smartfónov. Navrhnuté riešenie danej problematiky, ktoré rozširuje metódu uvedenú v [4], je založené na spracovávaní dát zrýchlenia a detekcii zmeny pohybu spôsobeného výťahom v reálnom čase. Na základe získaných údajov a uskutočnených testov je možné konštatovať, že výsledný algoritmus je schopný detegovať zmenu pohybu spôsobenú výťahom ak užívateľ stojí v pokoji a odlišiť pohyb výťahu od bežnej chôdze alebo nie príliš prudkého otáčania.

Kľúčové slová: *detekcia pohybu, smartfón, senzory.*

Obsah

| | |
|---|-----------|
| Úvod | 5 |
| 1 Senzory | 7 |
| 2 Filtrovanie dát | 9 |
| 2.1 Kĺzavý priemer | 9 |
| 2.2 LowPass filter | 9 |
| 2.3 Kalmanov filter | 9 |
| 3 Spôsoby detektovania začiatku a konca pohybu | 11 |
| 3.1 Metóda kritických bodov | 11 |
| 3.2 Klasifikácia aktivít | 12 |
| 3.3 Kombinácie senzorov | 13 |
| 3.4 Detekcia zmeny pohybu analýzou zrýchlenia | 13 |
| 3.4.1 Detekcia prahovou hodnotou | 13 |
| 3.4.2 Detekcia prahovou hodnotou a časom | 14 |
| 3.4.3 Detekcia prahovou hodnotou a počtom | 14 |
| 4 Testovanie | 16 |
| 4.1 Zber dát | 16 |
| 4.2 Testovanie kritických bodov | 16 |
| 4.3 Testovanie analýz zrýchlenia | 17 |
| 4.3.1 Detekcia prahovou hodnotou | 18 |
| 4.3.2 Detekcia prahovou hodnotou a časom (počtom) | 18 |
| 4.4 Priebeh testovania | 18 |
| Záver | 20 |

Úvod

Medzi aktúalne riešené oblasti patrí aj indoor navigácia, ktorá v sebe okrem výpočtu trasy k cieľu zahŕňa aj lokalizáciu v budove. Primárne zameranie je horizontálne určenie polohy v rámci daného poschodia, na ktorom sa používateľ navigácie práve nachádza, za účelom vypočítania trasy k požadovanému miestu. Pre tento účel boli vyvynuté algoritmy, ktoré využívajú rôzne metódy prístupu k danej problematike. Napríklad určenie polohy pomocou rôznych druhov signálov od telefónneho cez bluetooth až po wifi signál. Na druhej strane sú to metódy založené na počítaní krokov a natočenia využívajúc aj pravdepodobnostné algoritmy aby mohli čo najpresnejšie určiť polohu užívateľa a navigovať ho k jeho cieľovej destinácii.

Okrem horizontálnej existuje aj vertikálna lokalizácia. Jej účelom je určiť na ktorom poschodi sa užívateľ nachádza, ak je vo viac podlažnej budove. Existujú dva prístupy riešenia tejto problematiky. Prvým prístupom je vypočítanie poschodia na základe znalosti výšky v ktorej sa zariadenie nachádza (celkovej nadmorskej výšky od hladiny mora alebo od nejakého referenčného bodu, najčastejšie nadmorskej výšky budovy). Druhý spôsob je založený na predpokaldu znalosti aktuálneho poschodia a detektie jeho zmeny. Tento druhý prístup je často kombinovaný s horizontálnym spôsobom lokalizácie a znalosti mapy aby bolo zamedzené falosným detekciám, keďže určité techniky ako je napríklad meranie atmosférického tlaku, ktoré je jednou s možnosťí, nie sú úplne spoľahlivé, teda za určitých podmienok môže dôjsť k nežiadúcim zmenám. Takže na základe znalosti mapy a aktuálnej horizontálnej polohy je zmena poschodia akceptovaná iba vtedy, ak sa užívateľ nachádza v blízkosti miesta, v ktorom k takejto zmene môhlo dôjsť.

Dôvodom riešenia prestnosti vertikálnej lokalizácie, je spoľahlivosť navigácie v budovách. Za predpokladu, že sa užívateľ nachádza napríklad v nákupnom centre, ktoré má pre každé poschodie totožné, poprípade veľmi podobné rozloženie miestností, pre navigovanie užívateľa v rámci jedného poschodia, nemá veľký vplyv aké je jeho skutočná vertikálna poloha, pretože trasa k vertikálnej cieľovej pozícii je tá istá. Ak je ale cieľová pozícia na inom poschodi ako to na ktorom sa momentálne nachádza užívateľ a zároveň navigačný program nemá správne údaje o jeho vertikálnej polohe, môžu sa udiat' na-

sledujúce prípady (samořejme aj prípad správnej navigácie). Užívateľ je navigovaný k cieľu v rámci aktuálneho poschodia, ale ten je v skutočnosti o niekoľko poschodí nad poprípade pod ním. Navigácia ho zavedie správnym horizontálnym smerom, avšak o ne-správny počet poschodí. Navigácia ho pošle na iné poschodie, aj keď je na správnom. V najhoršom prípade ho navigácia zavedie opačným vertikálnym smerom a bude sa musieť prejsť dvojnásobnú vzdialenosť aby sa dostal k požadovanému cieľu. Dôležitosť správnej detekcie poschodia vzrástá za okolnosti, ak budova, v ktorej sa práve užívateľ nachádza má pre poschodia rôzne rozloženia miestností, poprípade aj parkovacie miesta v rámci budovy. Nesprávne určené poschodie môže spôsobiť, že užívateľ je nasmerovaný k zaparkovaným autám a nie k požadovanej lokácii. Preto je z tohto hľadiska prenosnosť vertikálnej lokalizácie veľmi dôležitá.

Jedným zo zariadení, na ktorých beží navigačný systém je aj smartfón. Ten má ale určité obmedzenia, čo sa týka schopnosti poskytnúť všetky kľúčové informácie pre navigačný proces. Dané obmedzenia závisia aj od výrobcu a verzie zariadenia, keďže niektoré hodnoty využívané navigáciou je možné získať len pomocou špecifického hárverového vybavenia smartfónu, ktoré nemusí byť jeho súčasťou. V prípade nedostupnosti schopnosti získať danú informáciu, môže byť určitá skupina algoritmov, najmä pre vertikálnu lokalizáciu pre dané zariadenie nepoužiteľná.

Ako už bolo spomenuté, zmena poschodia je možná iba na určitých miestach v rámci budovy. Tými miestami sú schody, eskalátory a výtahy. Pri všetkých týchto miestach je možné využiť meranie atmosférického tlaku a na základe neho určiť zmenené poschodie [1] alebo detektovať, že je vykonávaný pohyb v danom prostredí a na základe toho aplikovať algoritmus pre určenie zmeny poschodia. V prípade kráčania po schodoch je to napríklad metóda počítania prejdených schodov smerom nahor, nadol. Pre výtah a eskalátor je možné aplikovať rozpoznávanie aktivít zrýchlenia [2], určiť ich pomocou kombinácie detekcie zmien v atmosférickom tlaku, magnetickom poli a zrýchlenia [3] alebo pohyb výtahu len na základe zrýchlenia [4].

1 Senzory

Senzory sú zariadenia zaznamevajúce hodnoty určitej fyzikálnej veličiny. Podľa toho, aký typ veličiny merajú sa rozdeľujú do troch skupín. Pohybové senzory merajú akceleračné a rotačné sily. Senzory prostredia zaznamenávajú rôzne parametre, napríklad: teplota a tlak okolitého prostredia, osvetlenie a vlhkosť. Pozičné senzory merajú fyzickú pozíciu zariadenia. Z hľadiska spôsobu získavania dát sa delia na hardvérové a softvérové senzory. Hardvérové senzory sú fyzické komponenty zabudované do mobilného zariadenia. Získavajú dátu priamym meraním špecifickej vlastnosti prostredia. Softvérové senzory, nazývané aj virtuálne, získavajú dátu pomocou iných hardvérových senzorov.

Pohybové senzory zahŕňajú hardvérové senzory akcelerometer, gyroskop a v závislosti od prevedenia, bud' hárverové alebo softvérové senzory: gravitačný senzor, lineárny akcelerometer, rotačný vektor,detektor krokov, počítadlo krokov, senzor náhleho pohybu. Zatiaľ, čo akcelerometer a gyroskop sú pomerne rozšírené, prítomnosť softvérových senzorov v zariadení sa lísi v závislosti od dostupnosti potrebných hardvérových senzorov. Pohybové senzory sa využívajú na monitorovanie pohybu zariadenia vzhľadom na používateľa, ale aj na okolité prostredie. Senzory v tejto kategórii majú ako výstup viacdimenzionálne pole hodnôt.

Senzory prostredia sú hardvérové a to znamená, že sú dostupné, len ak boli vbudované do zariadenia počas výroby. Patria sem senzory teploty, teploty okolia, svetla, tlaku a relatívnej vlhkosti. S výnimkou senzora pre svetlo, ktorý sa využíva pri kontrole automatického jasu dispeja, nie sú vždy dostupné v zariadeniach. Tieto senzory majú ako výstup jednu hodnotu.

Medzi **pozičné senzory** patria hardvérové senzory geomagnetického poľa a priblíženia. Okrem nich sú to senzory: herný vektor rotácie, geomagnetický vektor rotácie, orientačný senzor. Všetky senzory okrem senzora priblíženia, ktorý poskytuje ako výstup jedinú hodnotu, majú trojdimenzionálny výstup.

Akcelerometer meria v jednotkách SI m/s^2 v osiach x,y,z. Tento senzor zaznamenáva zrýchlenie pôsobiace na zariadenie. Avšak, keď je zariadenie v pokoji, napríklad leží položené na stole, zrýchlenie v osi z bude približne zodpovedať hodnote

gravitačného zrýchlenia 9.81 m/s^2 z dôvodu pôsobenia gravitačnej a tiažovej sily.

Barometer je senzor, ktorý z okolia získavá informácie o hondote atmosférického tlaku v hPa .

Magnetometer meria silu magnetického poľa v μT [5].

2 Filtrovanie dát

Dáta, ktoré sú výstupom akcelerometra obsahujú šum, ktorý je spôsobený najmä neprestnosťou senzora. Tento šum je možné odstrániť aplikovaním rôznych filtrovacích metód.

2.1 Kĺzavý priemer

Výstupom tejto metódy pre aktuálne nameranú hodnotu je priemer aktuálnej a $n-1$ predchádzajúcich hodnôt, kde n môže byť pevná konštantá alebo závislé od počtu nameraných hodnôt za určité časové obdobie. Výpočet je daný vzťahom

$$y_i = \left(\sum_{j=0}^{n-1} x_{i-j} \right) / n \quad (1)$$

kde n je počet hodnôt, ktoré sa priemerujú a y_i je výstupná hodnota, ktorá vznikne priemerovaním vstupných hodnôt $x_i, x_{i-1}, \dots, x_{i-n+1}$.

2.2 LowPass filter

LowPass filter bol vytvorený pre prepúšťanie hodnôt s nízkou frekvenciou. Novú i -tu hodnotu vypočíta rozložením váhy alfa, čo zvykne byť konštantá, medzi aktuálne nameranú i -tu hodnotu a predchádzajúci výstup tohto filtra. Určenie novej hodnoty je dané vzťahom

$$y_{i+1} = y_i + \alpha(x - y_i) \quad (2)$$

kde y_i je predchádzajúci výstup filtra, x je aktuálne nameraná hodnota a y_{i+1} je nová hodnota.

2.3 Kalmanov filter

Kalmanov filter je množina matematických rovníc, ktoré poskytujú efektívne riešené kurzívne výpočtové prostriedky na odhadnutie stavu procesu s minimalizovaním chyby. Stavom procesu sa nazýva sladovaná veličina, alebo vektor veličín.

Odhad stavu prebieha v dvoch fázach. Prvou fázou je predikcia. V tejto časti je na základe známych zákonov (pravidiel) vypočítaná predpokladaná hodnota, ktorá by mala byť nameraná, pričom tento predpoklad obklopuje oblasť pravdepodobných hodnôt, ktorá je daná rozptylom procesnej chyby.

Druhou časťou je aktualizácia meraním alebo aj oprava. V tejto časti je na základe rozptylu procesnej chyby a rozptylu chyby merania, ktorá je daná rozptylom šumu senzora, vypočítaná matica kalmanovho zosilnenia. Pomocou tejto matice je z predpokladanej a nameranej hodnoty odhadnutá najpravdepodobnejšia reálna hodnota, ktorá mala byť senzorom odmeraná. Kalmanov filter pracuje podľa nasledujúcej schémy.

1. Predikcia (Časová aktualizácia)

Na základe známych vzťahov, napríklad fyzikálnych zákonov, je upravený aktuálny stav systému x_k^- - s predpokladom, že tento stav je dosiahnutý - podľa nasledujúceho vzorca

$$x_k^- = Ax_{k-1} + Bu_{k-1} \quad (3)$$

v ktorom štvorcová matica A reprezentuje prechod z predchádzajúceho do aktuálneho stavu v prípade absencie riadiacej funkcie u . Matica B sa vzťahuje na riadiaci vstup u pre stav x .

Pre ďalší krok je prepočítaná matica kovariancie chyby P_k^- podľa vzťahu

$$P_k^- = AP_{k-1}A^T + Q \quad (4)$$

kde Q je matica kovariancie procesného šumu.

2. Oprava (Aktualizácia meraním)

Pomocou prepočítanej **maticy kalmanovho zosilnenia** K_k a aktuálnych nameraných hodnôt z_k je aktualizovaný konečný stav systému x_k v danom čase a matica kovariancie chyby P_k , kde H je matica meraných veličín a R je matica kovariancie meraného šumu [6].

$$K_k = P_k^- H^T (H P_k^- H^T + R)^{-1} \quad (5)$$

$$x_k = x_k^- + K_k(z_k - Hx_k^-) \quad (6)$$

$$P_k = (1 - K_k H) P_k^- \quad (7)$$

3 Spôsoby detekovania začiatku a konca pohybu

3.1 Metóda kritických bodov

V článku [4] zaoberajúcim sa určením prejdenej vzdialenosťi výťahu využitím akcelerometra smartfónu, vychádzajú zo zjednodušeného rozpoznávania aktivity používateľa na základe získaných dát zrýchlenia produkovaného výťahom. Keďže zmena pohybu výťahu vytvára zreteľné zrýchlenie vo vertikálnom smere nahor, poprípade nadol, v miestach začiatku a konca danej zmeny je výrazný rozptyl hodnôt, ako ukazuje obrázok 1. Tieto miesta sa nazývajú **kritické body**, ktoré je možné vidieť na obrázku 2, charakterizujúce pohyb výťahu. Získané dáta zo senzora akcelerometer sú skombinované do veľkosti vektora zrýchlenia, čo zabezpečí, že natočenie smartfónu nebude mať vplyv na detekciu.

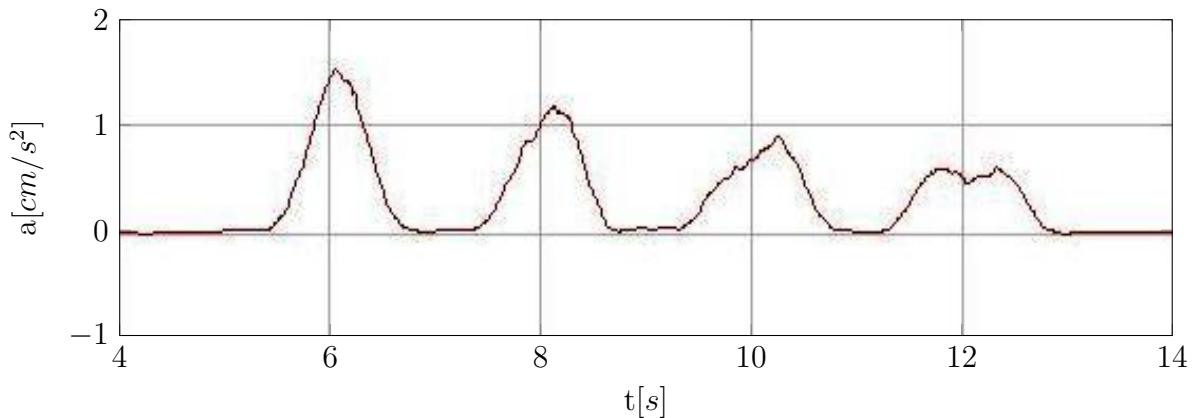
$$a = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (8)$$

Pre ľahšie spracovanie dát bol aplikovaný klízavý priemer, ktorý z dát odstránil šum. Každá skupina vyfiltrovaných hodnôt bola zviazaná s oknami fixnej dĺžky a následne pre každé okno bol vypočítaný rozptyl podľa všeobecného vyjadrenia, v ktorom σ^2 je rozptyl hodnôt x_0 až x_{n-1} a μ je priemer daných hodnôt.

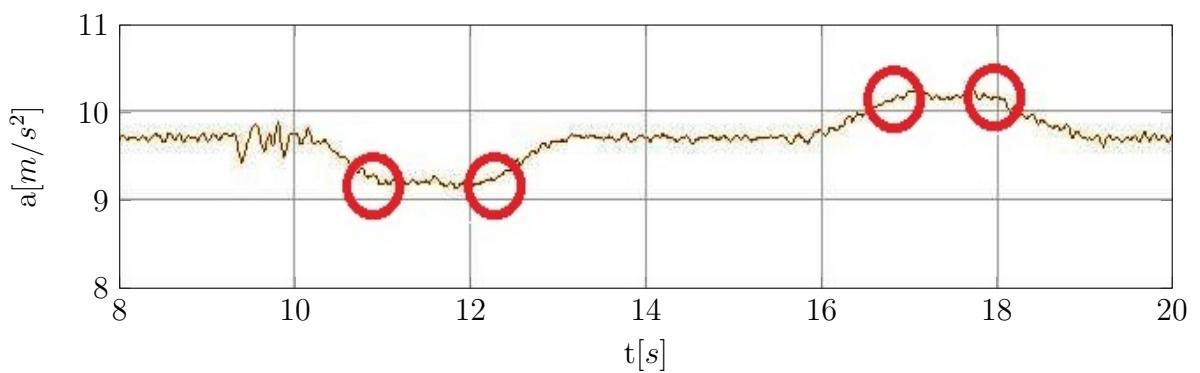
$$\sigma^2 = (\sum_{i=0}^{n-1} (x_i - \mu)^2) / n \quad (9)$$

Vypočítané hodnoty boli porovnané s množinou rozptylov (prahových hodnôt), ktoré boli získané pri počiatočnej analýze dát. Indexi okien, ktorých hodnoty presiahli prah boli uložené do poľa a potom znova analyzované pre získanie štyroch kritických bodov.

Táto metóda predpokladá vyextrahované zrýchlenie výťahu, takže zvýšený rozptyl bude v miestach kritických bodov. V ostatných prípadoch budú jeho hodnoty blízke hodnotám rozptylu keď je zariadenie v pokoji.



Obr. 1: Rozptyl filtrovaných dát zrýchlenia v oblasti kritických bodov



Obr. 2: Umiestnenie kritických bodov na dátach zrýchlenia výťahu

3.2 Klasifikácia aktivít

V článku [2] bol vertikálny pohyb výťahu detekovaný pomocou klasifikácie akceleračných vzoriek na základ časovej domény (priemeru, rozptylu, štandardnej odchýlky, rýchlosťi, vzdialenosťi) a frekvenčnej domény (energie a entropie). Pre rozdelenie vzoriek do aktivít bol použitý Weka samoučiaci sa softvér. Trénovací vstup pozostával z 176 inštancií aktivít od dvoch účastníkov. Pričom každá aktivita obsahovala aspoň 6 inštancií. Medzi trénovanie aktivity patrili okrem iných aj kráčanie po shodoch a používanie výťahu. V práci boli porovnané výsledky troch klasifikátorov, ktoré boli implementované v rámci systému Weka a dosahovali najlepšie výsledky a to J48, Naive-Bayes a FT. Klasifikátor je algoritmus na základe, ktorého sa určuje aktivita pre danú vzorku. Zvolený klasifikátor bol Naive-Bayes, pre dobrý klasifikačný výkon a krátky čas potrebný pre rozhodnutie. Výsledky dosiahnuté v práci ukázali, že všetky aktivity pohybu výťahu boli vyhodnotené správne.

3.3 Kombinácie senzorov

V článku [3] využívajú kombináciu senzorov akcelerometer, gyroskop, magnetometer, barometer zo zariadenia inerciálnej meracej jednotky, pre detekciu a rozoznanie pohybu platformy (výťahu a eskalátorov) od krokov v PDR indoor navigácií. Využívajú, že atmosférický tlak sa s výškou mení a odchýlka magnetometra je vo výťahu väčšia v porovnaní so státím alebo kráčaním mimo neho. Kombináciou týchto vlastností a vypočítanej rýchlosťi na základe dát z akceleromtra bol detekovaný pohyb výťahu alebo eskalátora podľa algoritmu 1. Výsledok dosiahnutý v článku ukázal iba jednu chybnú detekciu pohybu platformy spomedzi 10 meraní na trasách, ktoré obsahovali 27 výťahov a 36 eskalátorov.

Algoritmus 1 Algoritmus určenia pohybu na platforme (výťah, eskalátor) [3].

```
1: if rychlosť ≥ prahRychlosťi ⊕ rychlosťReset = true then
2:     pocitadlo ← cakaciaDoba/frekvenciaVzoriek
3:     pohybNaPlatforme ← true
4: else
5:     pocitadlo ← expiracnaHodnota
6: if zvysenyMagnetickyRozptyl = true ⊕ zvysenyNaklonVSignaleTlaku then
7:     pocitadlo ← cakaciaDoba
8:     pohybNaPlatforme ← true
9: else
10:    dekrementuj pocitadlo
11:    if pocitadlo = expiracnaHodnota then
12:        pohybNaPlatforme ← false
```

3.4 Detekcia zmeny pohybu analýzou zrýchlenia

3.4.1 Detekcia prahovou hodnotou

Detekcia prahovou hodnotou je postup, pri ktorom je sledovaná aktuálna hodnota merania a porovnávaná s hornou a dolnou prahovou hodnotou. Prahová hodnota je hodnota, ktorá musí byť dosiahnutá aby začala detekcia pohybu. Ak aktuálna hodnota zrýchlenia je menšia ako prahová hodnota, pričom predchádzajúca hodnota bola väčšia alebo rovná ako prahová hodnota, je detekovaný pohyb. Keďže zrýchlenie výťahu je v smere nahor aj nadol vzhládom na pokojovú hladinu, je potrebné rozlíšiť hornú a dolnú prahovú hodnotu.

3.4.2 Detekcia prahovou hodnotou a časom

Detekcia prahovou hodnotou a časom je založená na predpoklade, že doba trvania zrýchlenia spôsobeného krokmy je kratšia, ako doba trvania zrýchlenia spôsobeného výťahom. Tento predpoklad je zahrnutý v časovej konštante, ktorá reprezentuje dobu trvania zrýchlenia, kedy už je zrýchlenie považované za výsledok pohybu výťahu. Pre každú množinu hodnôt nad hornou prahovou hodnotou je určená inicializačná a ukončovacia hodnotou okna. Inicializačnou hodnotou okna nazývame hodnotu zrýchlenia väčšiu alebo rovnú hornej prahovej hodnote a zároveň s predchádzajúcou hodnotou menšou ako horná prahová hodnota. Ukončovacou hodnotou okna nazývame hodnotu zrýchlenia, ktorá je mešia ako horná prahová hodnota a zároveň predchádzajúca hodnota zrýchlenia bola väčšia alebo rovná ako horná prahová hodnota. Analogicky pre dolnú prahovú hodnotu. Pred určením zmeny pohybu, je overené, či čas medzi inicializačnou a ukončovacou hodnotou okna je menší ako časová konštantu. Ak je táto podmienka splnená, zmena pohybového stavu nenastala. Týmto postupom je možné ignorovať nežiadúce zmeny spôsobené krátkodobým výkyvom zrýchlenia.

3.4.3 Detekcia prahovou hodnotou a počtom

Detekcia prahovou hodnotou a počtom, popísaná algoritmom 2, počíta koľko meraných hodnôt za sebou je väčších ako horná poprípade dolná prahová hranica. Výhodou od predchádzajúceho postupu, je že ak experimentmi zistíme, že sledovaný jav bude mať nad prahom určitý minimálny počet hodnôt, vieme týmto postupom eliminovať všetky neželané udalosti, ktoré sú z hľadiska trvania, kratšie ako sledovaná udalosť.

Algoritmus 2 Algoritmus na detekciu zmeny pohybu pre nameranú hodnotu v určitom čase. Pri inicializácii sa premenná *pocet* nastaví na 0, *pohyb* na false. Premenná *akceptujuciPocet* je minimálny počet hodnôt nad prahom aby došlo k zmene pohybového stavu.

```
1: if hodnota  $\geq$  prah then
2:   pocet  $\leftarrow$  pocet + 1
3: else
4:   if pocet  $\geq$  akceptujuciPocet then
5:     if pohyb = true then
6:       pohyb  $\leftarrow$  false
7:     else if pohyb = false then
8:       pohyb  $\leftarrow$  true
9:   pocet  $\leftarrow$  0
```

4 Testovanie

4.1 Zber dát

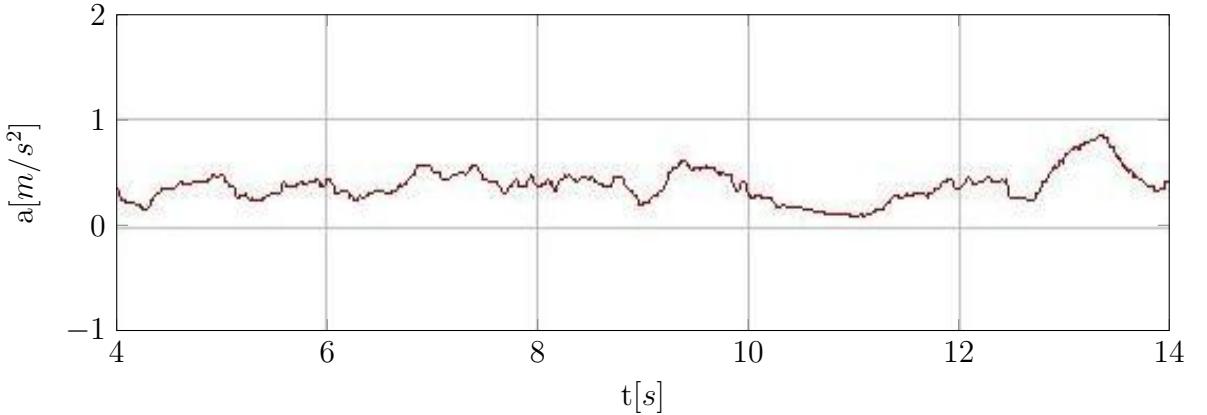
Na zber dát bolo použité zariadenie Samsung GT-19195 s Androidom vo verzii 4.4.2. Tento model poskytuje senzor akcelerometer typu MPU-6K. Zber dát prebiehal v troch výťahoch. Z toho dva výťahy boli novšieho typu a jeden výťah staršieho typu. Pri každom výťahu boli prevedené merania, kedy sa užívateľ nehýbal a merania , v ktorých boli zachytené aj kroky ked' užívateľ vchádzal do výťahu.

4.2 Testovanie kritických bodov

Kľúčovým bodom v tejto metóde je výpočet rozptylu, keďže sa na základe neho určujú kritické body. Ten sa vypočítava v statickom okne, teda ak sa pre výpočet v i -tom okne použijú hodnoty x_j až x_n , tak pre výpočet rozptylu v nasledujúcom okne sa použijú hodnoty x_{n+1} až x_m . Pričom väčší rozptyl môže byť napríklad medzi hodnotami x_{n-5} až x_{m-5} . Preto sme sa rozhodli počítať rozptyl z každých n hodnôt.

Najprv sme zistili, či je potrebné pre túto metódu aplikovať filter na dátá zrýchlenia. Pozorovania na vzorkách, ktoré obsahovali zrýchlenie spôsobené výťahom, ukázali, že v prípade nefiltrovaných dát zodpovedajúci rozptyl hodnôt v oblasti zrýchľovania, poprípade spomaľovania, nie je odlišiteľný od rozptylu v miestach, kde je užívateľ v pokoji alebo v rovnomenom pohybe, ako je možné vidieť na obrázku 3. To bolo zrejme spôsobené šumom produkovaným senzorom. Okrem metódy priemerovania hodnôt, ktorá bola spomenutá v článku [4], sme vyskúšali aj iné spôsoby filtrovania dát popísané v tejto práci. Po aplikovaní filtrov, sme mohli pozorovať, že rozptyl v oblasti kritických bodov bol odlišiteľný od okolitého rozptylu. Teda bolo možné na základe neho identifikovať kritické body.

Pre identifikáciu kritických bodov podľa rozptylu bola aplikovaná detekcia prahom. Pretože rôznej časovej dĺžke doby zrýchľovania zodpovedá iný priebeh hodnôt rozptylu, bolo potrebné otestovať túto metódu pre každý typ výťahu samostatne. Výsledky testovania tejto metódy sú zhrnuté v tabuľke 1.



Obr. 3: Rozptyl nefiltrovaných dát zrýchlenia v oblasti kritických bodov

| Metóda detekcie | Úspešnosť detekcie pri použití filtra (%) | | |
|-----------------|---|----------------|-----------------|
| | Kĺzavý priemer | LowPass filter | Kalmanov filter |
| Detekcia prahom | 46,15 | 25,64 | 17,94 |

Tabuľka 1: Výsledky testovania metódy kritických bodov pri aplikácií rôznych metód filtrovania dát na 30 vzorkách.

4.3 Testovanie analýz zrýchlenia

V tomto prípade neboli pozorované počas zberu dát odlišnosti v zrýchlení výťahov, ktoré by mohli spôsobiť potenciálnu chybu v ich detekcii. Pre otestovanie metód popísaných v kapitole 2 bolo potrebné určiť prahovú hodnotu avšak zrýchlenie merané akcelerometrom obsahuje gravitačnú zložku, ktorá sa môže lísiť na základe použitého zariadenia, ako sa ukázalo pri testovaní na inom zariadení. Preto je ešte pred použitím metódy detekcie odstránená gravitačná zložka. Tá je vypočítaná ako priemer nameraných hodnôt keď bolo zariadenie držané užívateľom v pokoji. Následný pohľad na priebeh dát, ktoré obsahovali iba zrýchlenie spôsobené výťahom, ukázal, že ak nie sú filtrované, je obtiažne určiť prahovú hodnotu. Po aplikovaní filtrovacích metód spomennutých v predchádzajúcich častiach práce, bolo možné jednotne stanoviť hornú a dolnú prahovú hranicu. Výsledky testovania tejto metódy sú zhrnuté v tabuľke 2.

| Metóda detekcie | Úspešnosť detekcie pri použití filtra (%) | | |
|-------------------------------------|---|----------------|-----------------|
| | Klzávý priemer | LowPass filter | Kalmanov filter |
| Detekcia prahovou hodnotou | 25,81 | 9,68 | 6,45 |
| Detekcia prahovou hodnotou a počtom | 100,00 | 100,00 | 100,00 |
| Detekcia prahovou hodnotou a časom | 100,00 | 100,00 | 100,00 |

Tabuľka 2: Výsledky testovania detekcie pohybu analýzou zrýchlenia pri aplikácií rôznych metód filtrovania dát na 30 vzorkách.

4.3.1 Detekcia prahovou hodnotou

Po aplikovaní klzávého priemeru, bolo správne detekovaných osem zo šestnástich vzoriek, ktoré obsahovali zrýchlenie výťahu. Z jedenástich vzoriek, ktoré obsahovali kroky a zrýchlenie výťahu, nebola žiadna správna detekcia. Rovnako aj na štyroch vzorkách, ktoré obsahovali kroky užívateľa bez zrýchlenia výťahu. Pri použití LowPass filtra v prípade vzoriek so zrýchlením výťahu boli úspešné tri detekcie a v prípade kalmanovho filtra už len dve. Na počet správnych detekcií pre vzorky, ktoré obsahovali kroky nemal vplyv spôsob filtrovania dát.

Chybné detekcie v prípade dát, ktoré obsahovali iba zrýchlenie výťahu, teda nebolo tam zrýchlenie vytvorené inou aktivitou používateľa smartfónu, boli spôsobené tým, že hodnoty zrýchlenia v krátkych časových intervaloch presiahli prahové hodnoty. Navyše pri testovaní tejto metódy na dátach, ktoré obsahovali zrýchlenie spôsobené krokmi užívateľa sme dospeli k nasledujúcemu pozorovaniu. Keďže zrýchlenie spôsobené krokmi užívateľa dosahuje hodnotu maximálneho zrýchlenia výťahu, nie je možné nastaviť prahovú hodnotu tak, aby zároveň neboli detekované kroky a bol detekovaný výťah.

4.3.2 Detekcia prahovou hodnotou a časom (počtom)

Výsledky týchto dvoch metód neboli závislé na spôsobe filtrovania dát zrýchlenia. Vo všetkých vzorkách bolo správne detekované zrýchlenie výťahu. Avšak, dotatočné testovanie ukázalo, že v prípade rýchlej chôdze alebo prudkého otáčania užívateľa, môžu vznikúť nesprávne detekcie.

4.4 Priebeh testovania

Pre účel testovania bol použitý program pre simuláciu senzorov, ktorý údaje získaval z logových súborov a do výstupného súboru boli na konci simulácie zapísané

výsledky v tvare:

názov vzorky:

názov aplikovaného pravidla pre detekciu : počet kontrolných bodov Názov vzorky bol názov logového súboru, z ktorého boli čerpané dátá. *Názov aplikovaného pravidla pre detekciu* obsahoval pomenovanie použitého filtra a spôsobu detekcie pohybu výťahu. *Kontrolný bod* bol zaznamenaný pri každej detekcii bodu prahovou hodnotou a pri každom určení pohybu detekciou prahovou hodnotou a časom (počtom). Overovanie výsledkov vychádzalo z názvu vzorky, ktorá mohla obsahovať nasledujúce anotácie:

1. **4K** ak boli v meraní spravené kroky
2. **NV** ak meranie neobsahovalo výťah
3. **_SH** ak bol smer pohybu nahor
4. **_SD** ak bol smer pohybu nadol
5. **_SN** ak smer pohybu nebol nahor ani nadol

Podľa obsahu názvu použitého pravidla bol nastavený počet očakávaných kontrolných bodov, ktoré boli vytvorené počas procesu detekcie pohybu.

1. detekcia prahom vytvára 4 kontrolné body
2. detekcia prahom a časom/počtom vytvárajú 2 kontrolné body
3. variance filter generuje dvojnásobný počet kontrolných bodov

Špeciálnym prípadom bolo, ak názov vzorky obsahoval anotáciu **NV**, kedy neboli očakávané žiadne kontrolné body, bez ohľadu na použité pravidlo detekcie.

Pre určenie správnosti výsledku bol porovnaný získaný a očakávaný počet kontrolných bodov. Špeciálne, ak bola prítomná anotácia **4K** a existoval výsledok vzorky bez danej anotácie, pričom tento bol určený ako nesprávny, výsledok s anotáciou **4K** bol tiež označený ako nesprávny.

Záver

Téma skúmaná v práci patrí do oblasti indoor navigácie, konkrétnie problému určenia zmeny poschodia. Za týmto účelom boli skúmané metódy detekcie vertikálneho pohybu v špecifických prostrediach, najmä výťahu, s využitím senzorov smartfóna zariadení.

Najprv bola prezentovaná jedna z existujúcich metód detekcie pohybu pomocou kritických bodov využívajúca zrýchlenie výťahu merané akcelerometrom. V rámci tejto metódy boli otestované tri spôsoby filtrovania dát: klzavý priemer, lowpass a kalmanov filter. Z pomedzi nich sa ukázal klzavý priemer ako najspoloahlivejší spôsob filtrovania pre následný výpočet rozptylu a identifikáciu kritických bodov.

Vychádzajúc z metódy kritických bodov boli navrhnuté postupy analyzovania dát zrýchlenia v reálnom čase: detekcia prahovou hodnotou, detekcia prahovou hodnotou a počtom, detekcia prahovou hodnotou a časom. Každý z uvedených postupov bol otestovaný v kombinácii s vyššie uvedenými filtrovacími metódami na rovnakej množine dát ako metóda kritických bodov, pričom spôsob filtrovania neovplyvnil výsledky pri aplikovaní detekcie prahovou hodnotou a časom (počtom), ktoré na daných vzorkách dosiahli spomedzi všetkých otestovaných metód najlepšiu úspešnosť.

V budúcnosti je možné vyskúšať kombináciu akcelerometra s inými senzormi smartfónu ako sú napríklad magnetometer alebo barometer. Ďalšou možnosťou v budúcnosti je pokúsiť sa integrovať navrhnutý algoritmus do detekcie zmeny poschodia v indoor navigácii.

Zoznam použitej literatúry

- [1] XIA, H. et al., 2015. Using Multiple Barometers to Detect the Floor Location of Smart Phones with Built-in Barometric Sensors for Indoor Positioning. In: *Sensors*[online]. Vol 15, no 4.
- [2] RADU, V. - MARINA, M. K., 2013. Himloc: Indoor smartphone localization via activity aware Pedestrian Dead Reckoning with selective crowdsourced Wifi fingerprinting. In: *2013 International Conference on Indoor Positioning and Indoor Navigation*. IEEE, s. 1-10. ISBN 978-1-4799-4043-1.
- [3] KAISER, S. - LANG, Ch., 2016. Detecting elevators and escalators in 3D pedestrian indoor navigation. In: *2016 International Conference on Indoor Positioning and Indoor Navigation*. IEEE, s. 1-6. ISBN 978-1-5090-2425-4.
- [4] MARTINEZ, A. - HIROI, K. - KAWAGUCHI, N., 2015. Design and implementation of algorithm for estimation of elevator travel distance using smartphone accelerometer. In *Adjunct Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2015 ACM International Symposium on Wearable Computers*. New York : ACM, s. 1489-1497. ISBN 978-1-4503-3575-1.
- [5] Sensors Overview. *Android Developers*[online]. Dostupné na: https://developer.android.com/guide/topics/sensors/sensors_overview.html
- [6] WELCH, G. - BISHOP, G., 2006. *An Introduction to the Kalman Filter*. 2. prep. a dopl. vyd. Chapel Hill : Department of Computer Science University of North Carolina at Chapel Hill. TR95-041.