Článok k bakalárskej práci

Slavomír Slovenkai

Univerzita Pavla Jozefa Šafárika v Košiciach

Abstrakt Práca sa zaoberá skúmaním možností detekcie pohybu používateľa smartfón zariadenia v určitých indoor prostrediach.

1 Úvod

Navigácia v budovách nemôže využívať GPS lokalizačný systém kvôli blokovaniu signálu stavebnými prvkami budovy. Preto boli vyvinuté rozličné metódy lokalizovania používateľa nejakého zariadenia (smartfón, tablet, ...). K tomuto účelu sa využívajú senzory dostupné na cieľových zariadeniach. Jednou z možností je zisťovanie polohy pomocou bezdrôtových lokalizačných systémov využívajúc wifi signál, Bluetooth alebo sú to systémy ako VLC (sledovanie svetla) a kombinácie rôznych senzorov (akcelerometer, barometer, magnetometer, ...). Pri viacposchodových budovách je dôležitá správna lokalizácia poschodia. Nesprávne určenie má napríklad za následok zle vypočítanú trasu k požadovanému cieľu. Wifi a Bluetooth lokalizácia využíva signál vysielaný zo zariadení rozmiestnených po budove. Pre wifi sa môže využiť fungujúca infraštruktúra a pre Bluetooth sa používajú zariadenia vysielajúce tento signál. Obidva tieto prístupy vedia zabezpečiť detekciu poschodia [1,2]. Avšak Bluetooth vysielače, ktoré dosahujú presnosť do jedného metra (presnosť wifi systému je 5-15 metrov) majú dosah iba do 30m na rozdiel od 150m, čo je dosah wifi [3,4]. To znamená, že ich počet narastá s veľkosťou plochy, ktorú je potrebné pokryť. Okrem toho je používanie wifi a Bluetooth energeticky niekoľkonásobne drahšie ako napríklad používanie akcelerometra. Metódy, ktoré nevyužívajú počitanie vzdialenosti od pevne známych bodov, počítajú zmenu výšky, na základe ktorej sú schopné určiť o koľko poschodí sa zmenila poloha zariadenia.
Táto zmena nastáva okrem kráčania po schodoch pri využití eskalátorov a výťahov, kedy užívateľ sám pohyb nevykonáva. V týchto prípadoch je potrebné určiť prejdenú vertikálnu vzdialenosť. Naším cieľom je preskúmať metódy, ktoré sa týmto problémom zaoberajú, aspoň jednu z nich prakticky overiť a prípadne navrhnúť vylepšenia metódy detekcie poschodia.

1.1 Senzory

V dnešnom smartfóne sa nachádzajú senzory, ktoré zbierajú rôzne informácie zo svojho okolia. Smartfón dokáže okrem príjmania signálov ako wifi a Bluetooth merať rôzne veličiny. Medzi ne patria: zrýchlenie, gravitácia, vektor otočenia, magnetické pole, tlak vzduchu, osvetlenie, ... Senzory implementované do smartfónov nie sú presné. Okrem skutočných hodnôt merajú šum, ktorý je možné čiastočne odfiltrovať použitím metód: kĺzavý priemer, lowpass filter, kalmanov filter.

1.2 Relevantné senzory pre výťah

Akcelerometer sa radí medzi pohybové senzory a meria zrýchlenie v m/s^2 pôsobiace na zariadenie.
Využitie: Výťah je zariadenie, ktoré vykonáva iba vertikálny pohyb. Z tohto dôvodu môžeme predpokladať výrazné zmeny rýchlosti vo vertikálnom smere a preto jednou s veličín ktorú budeme sledovať je zrýchlenie.
Barometer patrí medzi senzory prostredia a meria okolitý tlak vzduchu v hPa

alebo *mbar*.
So zmenou výšky je spojená aj zmena atmosférickeho tlaku.
Gyroskop meria natočenie zariadenia v rad/s okolo každej z troch osí [5].

2 Existujúce metódy

2.1 Meranie zrýchlenia a identifikácia kritických bodov

Kritický bod označuje hodnotu alebo udalosť v čase, ktorá je pre daný experiment z určitého hľadiska významná. Pre výťah sú význačné nasledujúce kritické body: výťah začal zrýchľovať, výťah ukončil zrýchľovanie, výťah začal spomaľovať, výťah ukončil spomaľovanie.
Jedným zo spôsobov ako získať tieto kritické body je počítanie rozptylu (variance). Táto metóda je založená na predpoklade plynulého zrýchľovania alebo spomaľovania objektu, takže v momente začatia a ukončenia zrýchľovania alebo spomaľovania je zaznamenaný výrazný rozptyl nameraných hodnôt a tie miesta sa označujú ako kritické body [6].

2.2 Meranie atmosférického tlaku

Atmosférický tlak s narastajúcou nadmorskou výškou klesá, čo je spôsobené rednutím vzduchu. Tento fenomén sa dá využiť pre výpočet aktuálnej výšky za predpokladu znalosti aktuálneho tlaku ovzdušia v určitých bodoch nadmorskej výšky, ktoré slúžia ako kontrolné hodnoty pre detekciu zmeny poschodia [7].

2.3 Weka a klasifikácia aktivít

Weka je samoučiaci sa softvér, ktorý sa používa na klasifikáciu akceleračných vzoriek do aktivít (státie, chodenie, výťah pohyb hore, výťah pohyb dole, ...). Pre účely klasifikácie sa použili priemer, rozptyl, štandardná odchylka, rýchlosť, vzdialenosť a iné. Údaje zrýchlenia sú posielané pre klasifikáciu aktivity, aby sa určilo, aká aktivita je práve vykonávaná [8].

3 Spôsoby vyhladzovania dát

3.1 KÍzavý priemer

KÍzavý priemer eliminuje šum vzniknutý pri meraní, priemerovaním určitého počtu hodnôt. Je daný vzťahom

$$y_i = (\sum_{j=0}^{n-1} x_{i+j})/n \tag{1}$$

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

3.2 Low pass filter

Low pass filter bol navrhnutý pre prepustenie signálu s nízkou frekvenciou a utlmovanie signálu s vysokou frekvenciou. Jednou z verzíi tohto filtra je Simple infinite impulse response filter, ktorá sa používa na vyhladzovanie dát.

V každom kroku je nová aktuálna hodnota y_{i+1} vypočítaná ako súčet predchádzajúcej hodnoty y_i a alfa násobku α z rozdielu nameranej hodnoty x a predchádzajúcej hodnoty y_i, kde α je filtračný činiteľ.

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

3.3 Kalmanov filter

Kalmanov filter je množina matematických rovníc, ktoré poskytujú efektívne rekurzívne výpočtové prostriedky na odhadnutie stavu procesu s minimalizovaním chyby. **Stavom systému** sa nazýva sledovaná veličina, alebo častejšie vektor veličín.

Proces sa skladá z dvoch krokov:

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

   $$x_k^- = Ax_{k-1} + Bu_{k-1} \tag{3}$$

   v ktorom štvorcová matica A reprezentuje prechod z predchádzajúceho stavu 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

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

   kde Q je matica kovariancie procesného šumu.

2. **Oprava (Aktualizácia meraním)**
   Pomocou prepočítanej **matice 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 [9].

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

   $$x_k = x_k^- + K_k(z_k - Hx_k^-) \tag{6}$$

   $$P_k = (1 - K_k H)P_k^- \tag{7}$$

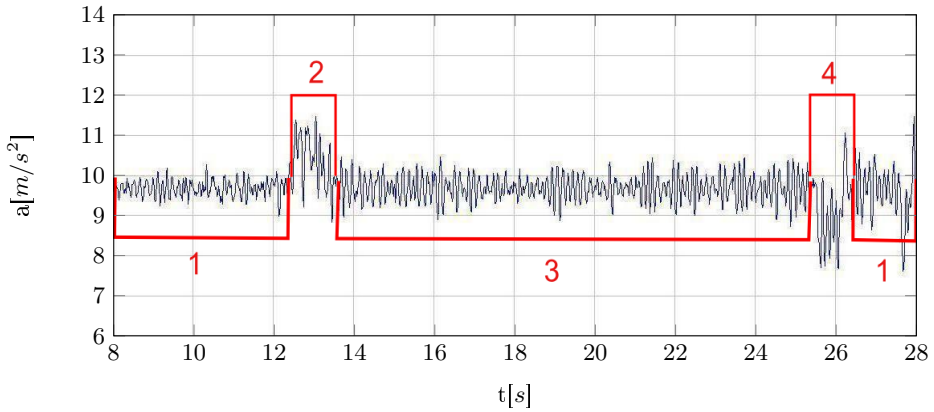

Obr. 1. Graf zrýchlenia v závislosti od času reprezentuje veľkosť zrýchlenia nameraného pri jazde výťahom smerom nahor. Zároveň sú na ňom znázornené jednotlivé etapy charakteristické pre výťah označené číslicami 1 až 4 v tomto poradí: státie, zrýchľovanie, pohyb, spomaľovanie.

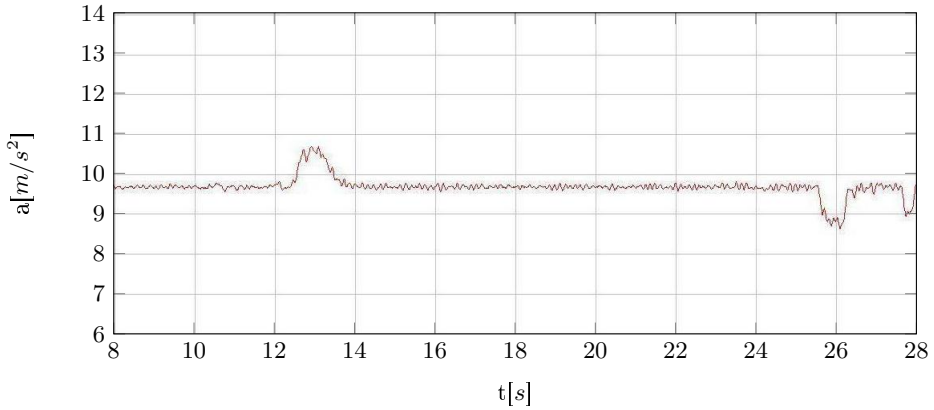

Obr. 2. Graf zrýchlenia v závislosti od času po aplikovaní kalmanovho filtra na dáta z Obrázku 1.

4 Detekcia zmeny pohybu analýzou zrýchlenia

4.1 Detekcia prahovou hodnotou

Detekcia prahovou hodnotou je postup, pri ktorom je sledovaná aktuálna hodnota merania a porovnávaná ju s prahovou hodnotou alebo prahom. Prahom v meraní nazývame hodnotu, nad ktorou namerané hodnoty spadajú do aktivity.

4.2 Detekcia prahovou hodnotou a počtom

Detekcia prahovou hodnotou a počtom počíta koľko meraných hodnôt za sebou je väčších ako prah. 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.

```
if hodnota >= prah then  pocet ← pocet + 1 ;
else
begin
    if pocet ≥ akceptujuciPocet then
    begin
        if pohyb = true then
        begin
            pohyb ← false
        end
        else if pohyb = false then
        begin
            pohyb ← true
        end
    end
    pocet ← 0
end
```

Algorithm 1: 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.

4.3 Detekcia prahovou hodnotou a časom

Detekcia prahovou hodnotou a časom počíta aký dlhý časový úsek boli sledované hodnoty bez prerušenia väčšie ako prah. Využitie a postup sú analogické ako pre detekciu prahovou hodnotou a počtom.

5 Záver

Na detekciu pohybu existuje viacero metód. Zatiaľ sme pomenovali niektoré metódy riešenia problému. Plánujeme overiť ďalšie možné metódy a funkčnosť daných metód pre rôzne zariadenia a používateľov.

Poďakovanie Ďakujem vedúcemu mojej bakalárskej práce Mgr. Opielovi za pomoc a inšpirujúce postrehy.

Literatúra

1. MANEERAT, K. - PROMMAK, C., 2014. An Enhanced Floor Estimation Algorithm for Indoor Wireless localization systems using confidence interval approach. In: *International Journal of Computer, Electrical, Automation, Control and Information Engineering*[online]. Vol. 8, no. 7.
2. ALESHY, F. - SEVAK, Z. - ARSLAN, T., 2011. Indoor Positioning with floor determination in Multi Story Buildings. In *2011 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*. IEEE. ISBN 978-1-4577-1803-8.
3. GAUDLITZ, E. Indoor navigation using WiFi as a positioning technology. In: *Infsoft*[online]. 2015-09-29 [cit. 2017-01-01]. Dostupné na: `https://www.infsoft.com/blog-en/articleid/40/indoor-navigation-using-wifi-as-a-positioning-technology`
4. GAUDLITZ, E. Indoor navigation & indoor positioning using Bluetooth. In: *Infsoft*[online]. 2015-12-14 [cit. 2017-01-01]. Dostupné na: `https://www.infsoft.com/blog-en/articleid/41/indoor-navigation-indoor-positioning-using-bluetooth`
5. Sensors Overview. *Android Developers*[online]. Dostupné na: `https://developer.android.com/guide/topics/sensors/sensors_overview.html`
6. 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.
7. 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.
8. 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.
9. WELCH, G. - BISHOP, G., 2006. *An Introduction to the Kalman Filter*. 2. prep. a dopl. vyd. Chapel Hill : Departrment of Computer Science University of North Carolina at Chapel Hill. TR95-041.