

# Rozpoznávanie aktivity používateľa smartfónu v indoor prostredí

Patrik Rojek

AIbe4, 2018 - 2019

**Abstrakt.** Práca sa zaoberá návrhom a implementáciou jednej z dostupných metód na rozpoznávanie aktivity užívateľa smartfónu v indoor prostredí s použitím zabudovaných senzorov v smartfóne. Hlavným cieľom práce je rozpoznať na základe poskytnutých vstupných dát zo senzorov smartfónu vykonávanú aktivitu s dostatočnou presnosťou pomocou implementovanej metódy.

**Kľúčové slová:** rozpoznávanie aktivity, senzor, akcelerometer, smartfón, indoor prostredie

## 1 Úvod

S pokrokom v oblasti miniaturizácie elektroniky a procesorov sa objavuje nová generácia smart zariadení na osobné monitorovanie a spracovanie osobných údajov. Ich spoločnou charakteristikou je bohatá sada rôznych integrovaných senzorov, od snímačov svetla a zotrvačníkov až po rádiové rozhrania, čo umožňuje aplikáciám bežiacim na týchto zariadeniach „zmapovať“ okolité prostredie. Namiesto použitia senzorov nezávisle, kombinovaním ich schopností snímania vznikajú zaujímavejšie a zložitejšie aplikácie (napr. Rozpoznávanie aktivity používateľov).

Tieto jednoduché, početné senzory poskytujú príležitosť pomôcť pri komplexnejších úlohách spojených s kombináciou schopností. Avšak vzhľadom na ich vnútornú povahu a charakteristiky snímania (napr. vzorkovacia rýchlosť a štatistické vlastnosti), integrácia prúdov senzorov je často veľmi náročná. Získavanie relevantných funkcií a zisťovanie korelácií medzi týmito vlastnosťami v rôznych spôsoboch snímania, aby sa zlepšila presnosť odozvy, je preto naliehavým problémom bezprostredného záujmu.

Je to náročný problém, pretože neexistujú priame spôsoby na to, ako z dát zaznamenaných pomocou rôznych senzorov určiť, že sa jedná o špecifickú ľudskú aktivitu. Každý subjekt totiž môže vykonávať danú aktivitu s významnými odchýlkami, čo má za následok zmeny zaznamenaných dát zo snímačov. Cieľom je teda zaznamenať dáta zo senzorov pre korešpondujúce aktivity vykonávané rôznymi subjektami, prispôbiť a zovšeobecniť model z týchto údajov tak, aby bolo s jeho použitím možné rozpoznať aktivitu nového nezávislého subjektu na základe jeho dát zo snímačov.

## 1.1 Indoor navigácia


Na rozdiel od outdoor navigácie, na ktorú sa využíva GPS signál, pri indoor navigácii je GPS signál tlmený, rozptýlený alebo úplne blokovaný stenami, strechami a celkovo konštrukciami budov alebo inými objektmi, vďaka čomu je prakticky nepoužiteľný.

Namiesto neho sa v indoor navigácii využívajú iné druhy signálov ako napríklad Wi-Fi, Li-Fi, Bluetooth, rádiové signály, dáta z rôznych dostupných senzorov a mnoho ďalších. Spoločne s týmito signálmi sa využívajú rôzne matematické a fyzikálne metódy, ktoré slúžia na spresnenie určenia polohy. V rámci predmetu tejto práce budeme implementovať práve jednu z existujúcich metód, týkajúcu sa rozpoznávania aktivity používateľa smartfónu, ktoré priamo súvisia a dajú sa následne využiť v indoor navigácii.

## 1.2 Rozpoznávanie aktivity

Rozpoznávanie aktivity užívateľa má v súčasnosti rôzne aplikácie v oblastiach navigácie, medicínskych službách, kde je monitorovanie fyzickej aktivity pacienta súčasťou liečby alebo diaľkové sledovanie pacientov so zdravotným postihnutím a seniorov, sociológie a iné. Existujú rôzne vyhodnocovacie metódy, z ktorých si niektoré podrobnejšie spomenieme v kapitole 2. Hlavnou myšlienkou je rozpoznať na základe získaných dát akú aktivitu používateľ vykonával. Práca spojená s rozpoznávaním ľudských aktivít je kombináciou spracovania údajov a následnej klasifikácie.

Keď používateľ vykonáva fyzickú aktivitu, ako je napríklad chôdza, počas používania smartfónu, je možné zaznamenávať hodnoty zo zabudovaných senzorov smartfónu, čo sa nazýva zhromažďovanie vzorkových dát. Tieto dáta sa následne filtrujú alebo aj predbežne spracovávajú a upravujú na požadovaný formát. Potom sa z nich dá extrahovať unikátna sada funkcií a nakoniec sa aplikujú algoritmy učenia na spracovanie klasifikácie. Akonáhle sa uložia známe vzory pre jednotlivé rozpoznávané aktivity, aplikácia sa pokúša spárovať resp. priradiť nové dáta so známymi vzormi na identifikáciu vykonávanej aktivity (viď. Obr.1).




Obr. 1: Schéma architektúry systému na rozpoznávanie aktivity.<sup>1</sup>

<sup>1</sup>Zdroj:

<https://www.resna.org/sites/default/files/conference/2014/Other/Gani/Fig1.png>

### 1.3 Sensory smartfónu


Senzory sú zariadenia, ktoré merajú hodnotu fyzickej energie a konvertujú ju na signál. Ako už bolo spomenuté smart zariadenia, medzi ktoré patria aj smartfóny, už v dnešnej dobe bežne obsahujú širokú ponuku senzorov spomedzi stoviek rôznych existujúcich druhov senzorov, ktoré merajú orientáciu, pohyb, svetlo a iné environmentálne podmienky. Smartfóny majú jednak hardvérové senzory, ktoré sú fyzicky prítomné v zariadení a priamo merajú vlastnosti okolitého prostredia, a jednak softvérové senzory, ktoré sú virtuálne. Softvérové senzory berú vstupy z jedného alebo viacerých hardvérových senzorov na následne výpočty. Sensory sa dajú deliť do rôznych skupín podľa rôznych kritérií. Ukážku jedného z možných rozdelení môžeme vidieť aj na Obr. 2.



Obr. 2: Sensory smartfónu.<sup>2</sup>

Medzi základné a najrozšírenejšie senzory, ktoré sa používajú v oblasti rozpoznávania aktivity a navigácii patria:

- **Akcelerometer** – Patrí medzi hardvérové senzory a je to jednoduché MEMS (Micro-electro-mechanical system) zariadenie, ktoré sa používa na meranie polohy, pohybu, náklonu, nárazov, vibrácií a zrýchlenia (jednotka zrýchlenia v  $m/s^2$ ) na každej z troch osí (v prípade trojosového akcelerometra). Namerané zrýchlenie zahŕňa nameranú zmenu rýchlosti spolu s gravitačným zrýchlením.



Obr. 3: Osi trojosového akcelerometra v smartfóne.


<sup>2</sup>Zdroj: <http://myphonefactor.in/2012/04/sensors-used-in-a-smartphone/>

- **Gyroskop** – Udáva rýchlosť otáčania zariadenia okolo každej z 3 osí. Inými slovami meria uhlovú rýchlosť. Hodnota rýchlosti otáčania je pozitívna v smere proti smeru hodinových ručičiek (pravidlo pravej ruky).
- **Kompas** – Kompas alebo magnetometer je hardvérový senzor, ktorým sa dá určiť veľkosť uhla, o ktorý sa zariadenie otáča vzhľadom na magnetický severný pól Zeme. Vieme ním teda určiť smer pohybu.
- **Barometer** – Udáva atmosférický tlak v jednotke hektopascal (hPa). Používa sa na výpočet zmeny nadmorskej výšky. Tento senzor je ale v porovnaní s predošlými v súčasnosti menej využívaný, pretože jeho výskyt v smartfónoch je stále dosť malý.

## 2 Prehľad súčasného stavu

Rozpoznávanie aktivity pomocou nositeľných senzorov je v súčasnosti veľmi aktívnou oblasťou výskumu. Existuje mnoho metód akými sa dá táto problematika riešiť. Spomenieme si teda niektoré z existujúcich klasifikačných algoritmov:

- **Naive Bayes** – jednoduchý pravdepodobnostný klasifikátor založený na Bayesovom pravidle. Takýto algoritmus bol použitý v [1], spolu s použitím algoritmov PAC a PDR.
- **Bayesovská sieť** – pravdepodobnostne orientovaný acyklický grafický model, ktorý reprezentuje súbor náhodných premenných a ich podmienené závislosti,
- **K-najbližší sused** – bezparametrová metóda na klasifikáciu objektov založená na hľadaní najbližších testovacích príkladov v množine funkcií,
- **Viacvrstvový perceptrón** – „Feedforward“ neurónová sieť (FNN), ktorá mapuje množinu vstupných údajov na množinu vhodných výstupov (viď. Obr. 4). Takýto algoritmus bol použitý v [2], kde bola dosiahnutá až 95% celková úspešnosť rozpoznávania ôsmich denných aktivít.
- **Rozhodovací strom** – pomocný rozhodovací nástroj, ktorého graf má stromovú štruktúru, Takýto algoritmus bol použitý v [3].
- **Logistická regresia** – typ regresnej analýzy na predpovedanie výsledku kategorickej závislej premennej na základe jednej alebo viacerých predvídateľných premenných



**Obr. 4: Ukážka štruktúry Feedforward neurónovej siete.<sup>3</sup>**

<sup>3</sup>Zdroj: <https://www.learnopencv.com/wp-content/uploads/2017/10/mlp-diagram.jpg>

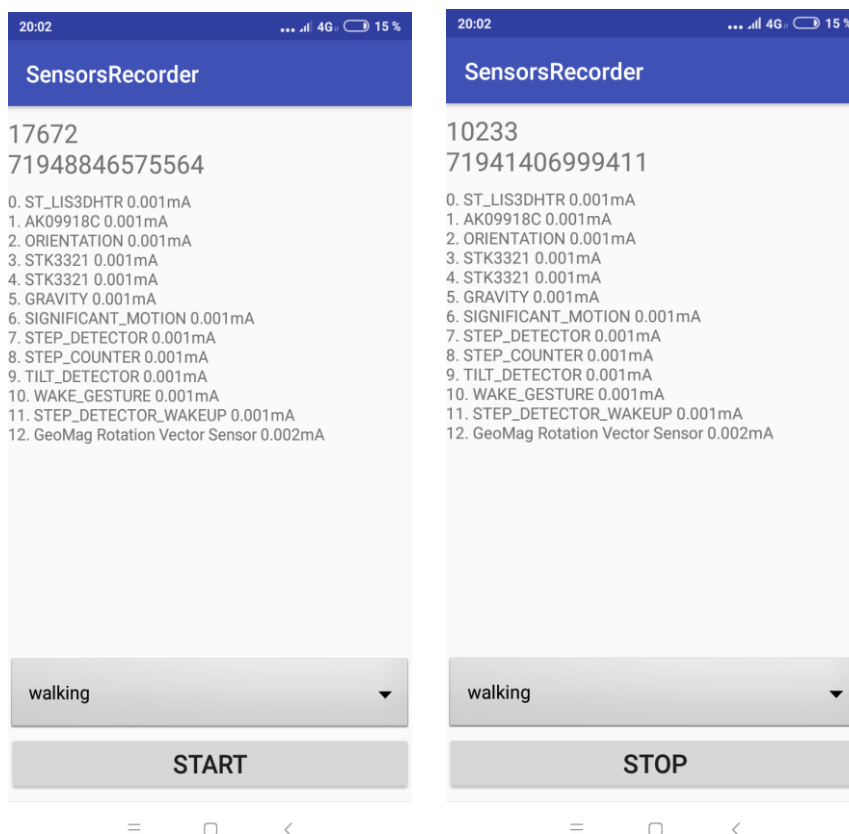
### 3 Zber a vykresľovanie dát

#### 3.1 SensorRecorder

Na zaznamenávanie údajov zo senzorov smartfónu sme použili vlastnú mobilnú aplikáciu SensorRecorder (vid' Obr. 5 a 6), ktorá zaznamenáva dáta zo všetkých dostupných senzorov v zariadení a ukladá ich do .csv textových súborov. Rozhodli sme sa zaznamenávať šesť rôznych aktivít a to:

- státie,
- chôdza,
- chôdza po schodoch (smerom hore/dole),
- a cesta výťahom (smerom hore/dole).

Aplikácia funguje tak, že užívateľ si z ponuky jednotlivých aktivít, ktoré chceme zaznamenávať, vyberie z dropdown listu jednu a následne stlačí tlačidlo START, čím sa zapne zaznamenávanie a nakoniec stlačením tlačidla STOP sa zaznamenávanie ukončí a vytvorený .csv súbor sa uloží v adresári aplikácie. Počas zaznamenávania aktivity sa dá zvoliť aj iná aktivita.



Obr. 5 a 6: Aplikácia SensorRecorder.


### 3.2 Vykresľovanie zaznamenaných dát

Na vykresľovanie zaznamenaných dát sme si s použitím Java knižnice JavaPlot, ktorá je založená na knižnici GNUPlot, naprogramovali jednoduchý program, v ktorom sa z nazbieraných dát v .csv súbore na vstupe prefiltrujú záznamy podľa vybraného senzora a zvolenej aktivity. Následne sa z nich vykreslí graf (vid'. Obr. 7).

Vodorovná os grafu predstavuje veličinu času v nanosekundách a horizontálna os zase veličinu celkového zrýchlenia v  $\text{m/s}^2$ , ktoré sme vypočítali vzťahom:

$$a_i = \sqrt{x_i^2 + y_i^2 + z_i^2}$$

, kde  $x_i$ ,  $y_i$  a  $z_i$  sú hodnoty nameraných zrýchlení z jednotlivých osí v danej nanosekunde  $i$ .



Obr. 5 a 6: Ukážka vykreslenia grafu pre aktivitu chôdza.

## 4 Záver

Doposiaľ sme sa zaoberali zaznamenávaním dát zo senzorov smartfónu a následne vykresľovaním grafov jednotlivých aktivít z nazbieraných dát. Ďalej plánujeme implementovať jednu z existujúcich klasifikačných algoritmov a následne ju otestovať a prezentovať dosiahnuté výsledky.

### PodĎakovanie

Týmto sa chcem poďakovať vedúcemu mojej bakalárskej práce RNDr. Miroslavovi Opielovi za pomoc s výberom témy bakalárskej práce, ochotu a cenné rady a pripomienky pri jej vypracovávaní.

## **Literatúra**

- [1]. Moder, T., Hafner, P., Wisiol, K. and Wieser, M., 2014, October. 3d indoor positioning with pedestrian dead reckoning and activity recognition based on bayes filtering. In Indoor positioning and indoor navigation (IPIN), 2014 international conference on (pp. 717-720). IEEE.
- [2]. Yang, J.Y., Wang, J.S. and Chen, Y.P., 2008. Using acceleration measurements for activity recognition: An effective learning algorithm for constructing neural classifiers. Pattern recognition letters, 29(16), pp.2213-2220.
- [3]. Anguita, D., Ghio, A., Oneto, L., Parra, X. and Reyes-Ortiz, J.L., 2012, December. Human activity recognition on smartphones using a multiclass hardware-friendly support vector machine. In International workshop on ambient assisted living (pp. 216-223). Springer, Berlin, Heidelberg.