

Rozpoznávanie aktivity používateľa smartfónu v indoor prostredí

Patrik Rojek

Vedúci práce: RNDr. Miroslav Opiela, Ústav informatiky, Prírodovedecká fakulta UPJŠ v Košiciach

Abstrakt

Práca sa zaoberá návrhom a implementáciou dvoch 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 danej implementovanej metódy.

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 zotrvačiek až po rádiové rozhrania, čo umožňuje aplikáciám bežiacim na týchto zariadeniach „zmapovať“ okolité prostredie. Namiesto použitia senzorov nezávisle, kombinovaním ich schopností snímajú 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 snímajú (napr. vzorkovacia rýchlosť a štatistické vlastnosti), integrácia zaznamenaných dát z jednotlivých senzorov je často veľmi náročná. Získavanie relevantných funkcií a zisťovanie korelácií medzi týmito vlastnosťami v rôznych spôsoboch snímajú, aby sa zlepšila presnosť odozvy, je preto naliehavým problémom.

Ako príklad na túto problematiku by sme mohli uviesť porovnanie aktivít ako chôdza, beh alebo kráčanie po schodoch. Tieto tri aktivity sa dajú označiť ako podobné, pretože pri všetkých sa dá pokladať jeden krok ako „základná“ jednotka, ktorá sa ale pri každej z aktivít inak prejaví v zaznamenaných dátach. Beh v porovnaní s chôdzou bude mať napríklad vyššiu frekvenciu krokov v závislosti od času a zase dáta kráčania po schodoch sa budú oproti chôdzi odlišovať meniacou sa vertikálnou pozíciou subjektu, či už smerom nahor alebo nadol.

Cieľom je teda zaznamenať dáta zo senzorov pre korešpondujúce aktivity vykonávané rôznymi subjektami, zostaviť, prispôbiť a zovšeobecniť model z týchto údajov tak, aby bolo s jeho použitím možné rozpoznať aktivitu nového nezávislého subjektu na základe dát získaných z jeho snímačov.

Rozpoznávanie aktivity

Hlavnou myšlienkou je rozpoznať na základe získaných dát akú aktivitu používateľ vykonáva. Práca spojená s rozpoznávaním ľudských aktivít je kombináciou spracovania údajov a následnej klasifikácie.


Väčšinou proces rozpoznávania aktivity prebieha tak, že 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.




Zber a spracovanie dát

Ako prvú vec v rámci praktickej časti tejto práce sme museli získať nejaké surové dáta. Pre obe metódy na rozpoznávanie aktivity, ktoré sme implementovali, sme sa rozhodli využívať iba dáta z akcelerometra. Čo sa týka rozpoznávaných aktivít, ktorým sme sa venovali, rozhodli sme sa zaznamenávať šesť rôznych aktivít a to:

- státie,
- chôdza,
- chôdza po schodoch smerom hore,
- chôdza po schodoch smerom dole,
- cesta výťahom smerom hore,
- cesta výťahom smerom dole.



Postupovali sme tak, že sme pomocou pomocnej mobilnej aplikácie zozbierali surové dáta, ktoré sme ďalej spracovávali, prefiltrovali a potom použili na vytvorenie datasetu, ktorý sa neskôr používa ako vstup pre implementované metódy.

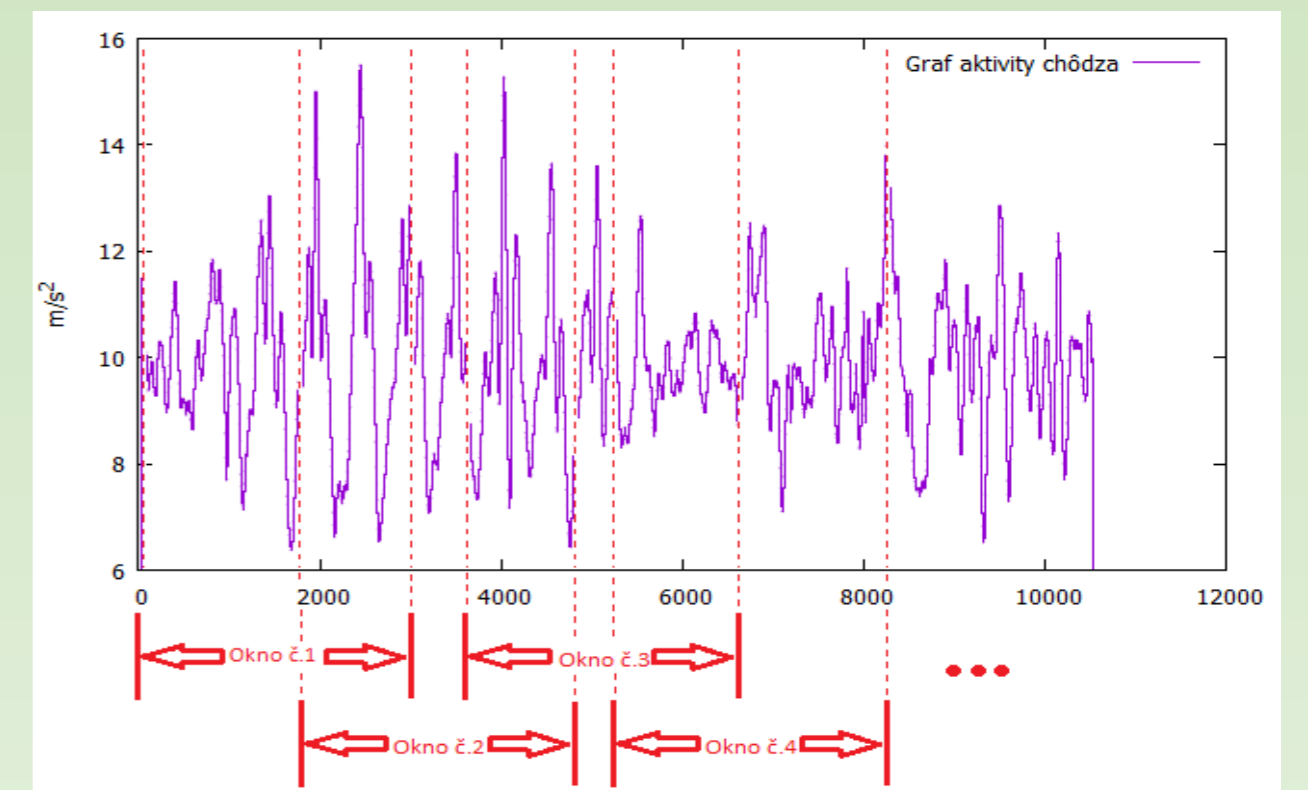


Viacvrstvá perceptrónová neurónová sieť

Prvou metódou na rozpoznávanie aktivity je viacvrstvá perceptrónová neurónová sieť. Na jej implementáciu sme použili programovací jazyk Java a knižnicu Neuroph, ktorá slúži na implementáciu mnohých známych architektúr neurónových sietí. Naším zámerom pri použití tejto metódy bolo pozrieť sa dáta zo statického hľadiska a experimentálne zistiť, či sa dá takýmto spôsobom s dostatočnou presnosťou určiť o akú aktivitu ide, keď na vstupe dostaneme iba krátky úsek dát o dĺžke maximálne pár sekúnd.

Keďže získane dáta jednotlivých aktivít sú rôznej dĺžky, rozhodli sme sa ich rozdeliť na okná jednotnej dĺžky, ktoré sa navzájom čiastočne prekrývajú tak, ako je to znázornené na nasledujúcom obrázku.

Keďže získane dáta jednotlivých aktivít sú rôznej dĺžky, rozhodli sme sa ich rozdeliť na okná jednotnej dĺžky, ktoré sa navzájom čiastočne prekrývajú tak, ako je to znázornené na nasledujúcom obrázku.



Extrahcia vlastností z okna je dosť efektívna cesta ako zachovať odlišiteľnosť aktivít a môžeme tak reprezentovať charakteristické vlastnosti rôznych signálov aktivít. Z každého takto získaného okna sme s použitím Java knižnice Apache Commons Math vypočítali hodnoty pre nami zvolený zoznam ôsmich vlastností:

- priemer,
- štandardná odchýlka,
- variancia,
- priemerná absolútna odchýlka,
- kvadratický priemer,
- medzikvartilový rozsah,
- energia,
- korelácia medzi osami.

Týchto 8 vlastností sme vypočítali pre každú z troch osí akcelerometra, čo nám dokopy dáva 24 atribútov pre každé okno. Všetky dostupné namerané dáta sme takto spracovali a získali sme náš výsledný dataset, ktorý sme ďalej použili ako vstup pre našu neurónovú sieť.

Záver

Doposiaľ sme sa zaoberali zaznamenávaním, filtrovaním a spracovaním nazbieraných dát zo senzorov smartfónu a následne implementáciou prvej zo zvolených metód na rozpoznávanie aktivity. Ďalej plánujeme implementovať druhú z metód a následne prezentovať dosiahnuté výsledky pre každú z implementovaných metód.

Literatúra

- [1]. Moder, T., Hafner, P., Wisioł, 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.