

Rozpoznávanie aktivity používateľa smartfónu v indoor prostredí

Patrik Rojek

AIbe4, 2018 - 2019

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.

Kľúčové slová: rozpoznávanie aktivity, senzor, akcelerometer, smartfón, indoor prostredie, neurónová sieť, perceptrón, Long Short-Term Memory (LSTM)

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 zaznamenaných dát z jednotlivých 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.

Je to náročný problém, pretože neexistujú priame spôsoby na to, ako z dát zaznamenaných pomocou rôznych senzorov jednoznačne určiť, že sa jedná o špecifickú ľudskú aktivitu. Každý subjekt totiž môže kvôli rôznym vplyvom okolitého prostredia alebo aj možným fyziologickým resp. anatomickým rozdielom vykonávať danú aktivitu s významnými odchýlkami, čo má za následok zmeny zaznamenaných dát zo snímačov.

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, prispôsobiť 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.

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 blokový stenami, strechami a celkovo konštrukciami budov alebo inými objektmi, vďaka čomu je prakticky nepoužiteľný. Namiesto neho sa 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. Pri lokalizácii v budovách sa navyše uvažuje aj aktuálne poschodie a zmena poschodia, či už prostredníctvom schodov, výťahom alebo eskalátorom.

Väčšina aplikácií na indoor navigáciu je veľmi podobná s navigačnými systémami, ktoré v súčasnosti používame v našich automobiloch. Takéto aplikácie sa využívajú v mnohých oblastiach ako napríklad na navigáciu v úradných budovách, obchodných centrách, vlakových staniciach, letiskách a pod. a funguje tak, že zobrazuje smery na digitálnej mape. Indoor navigácia s automatickým určením polohy sa zvyčajne používa ako klientska aplikácia. To znamená, že pozícia je určená priamo na smartfóne užívateľa.

V rámci predmetu tejto práce budeme implementovať práve dve z existujúcich metód, týkajúce 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 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 (viď. Obr.1).



Obr. 1: Schéma architektúry systému na rozpoznávanie aktivity.

1.3 Sensory smartfónu


Sensory 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.

Jedným z možných delení senzorov môže byť na:

- *Pohybové senzory* – merajú akceleračné a rotačné sily pozdĺž troch osí a táto kategória zahŕňa akcelerometre, gravitačné senzory, gyroskopy, a rotačné vektorové senzory.
- *Polohové senzory* – merajú fyzickú polohu zariadenia a patria sem snímače orientácie a magnetometre.
- *Environmentálne senzory* – merajú rôzne parametre prostredia, ako je teplota a tlak okolitého vzduchu, osvetlenie a vlhkosť a radíme medzi ne snímače teploty, barometre a fotometre.

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. 2: Osi trojosového akcelerometra v smartfóne.

- **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 súčasných metód na rozpoznávanie aktivít

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 (Pedestrian activity classification) a PDR (Pedestrian dead reckoning).
- **Bayesovská sieť** – pravdepodobnostne orientovaný acyklický grafický model, ktorý reprezentuje súbor náhodných premenných a ich podmienené závislosti,
- **K-najbližších susedov** – bezparametrová metóda na klasifikáciu objektov založená na hľadaní najbližších testovacích príkladov v množine funkcií,
- **Viacvrstvomá perceptrónová neuronová sieť** – je typom doprednej neurónovej siete označovanej aj FNN (Feedforward neural network), 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.

3 Zber a filtrovanie 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 rozoznávaných 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 s názvom SensorRecorder zozbierali surové dáta, ktoré sme ďalej spracovávali, prefiltrovali a potom použili na vytvorenie datasetu, ktorý sa neskôr používa ako vstup pre implementované metódy.

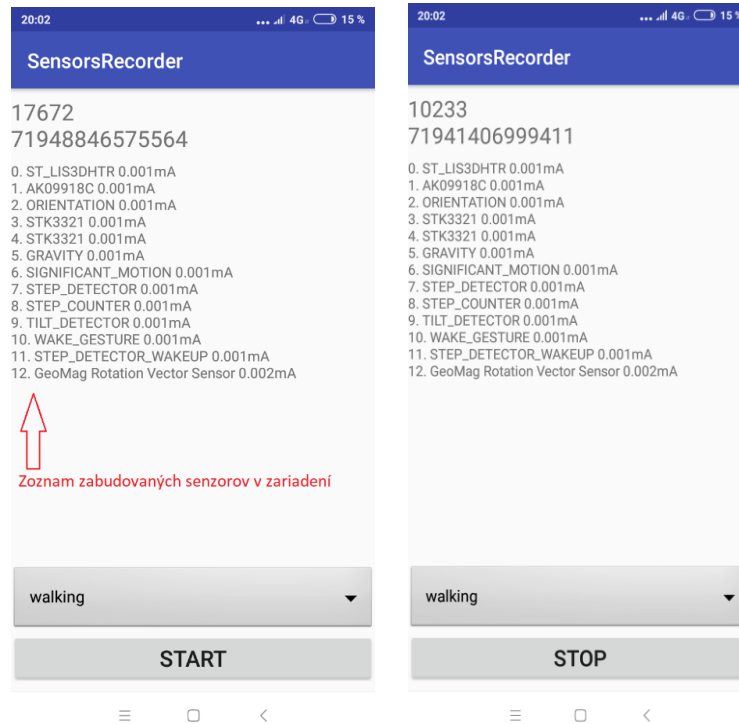
3.1 Zber dát

Na zaznamenávanie údajov zo senzorov smartfónu sme použili vlastnú mobilnú aplikáciu SensorRecorder (vid' Obr. 3 a 4), ktorá zaznamenáva dáta zo všetkých dostupných senzorov v zariadení a ukladá ich do .csv textových súborov v nasledujúcom formáte:

- čas, v ktorom bol daný záznam nameraný v jednotkách ms
- názov zaznamenávanej aktivity spomedzi 6 aktivít, ktorými sa zaoberáme
- názov senzora
- hodnoty z daného senzora v danom čase pre danú aktivitu

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 z listu zvoliť aj iná aktivita, keďže tieto aktivity bežne vykonávame po sebe napr. chôdza -> státie -> cesta výťahom a pod., čo nám umožňuje kontinuálne nahrávať jednotlivé aktivity za sebou do rovnakého súboru, čo bude v konečnom dôsledku efektívnejšie keď budeme neskôr dané dáta nahrávať pri ich spracovávaní.



Obr. 3 a 4: Aplikácia SensorRecorder.

3.2 Ukážka zaznamenaných dát

Na vykresľovanie zaznamenaných dát sme si použili Java knižnicu JavaPlot¹, ktorá je založená na knižnici GNUPlot, naprogramovali program na prefiltrovanie nazbieraných dát v .csv súbore na vstupe prefiltrujú záznamy podľa vybrateho senzora a zvolenej aktivity. Následne sa z nich vykreslí graf (vid'. Obr. 5-7).

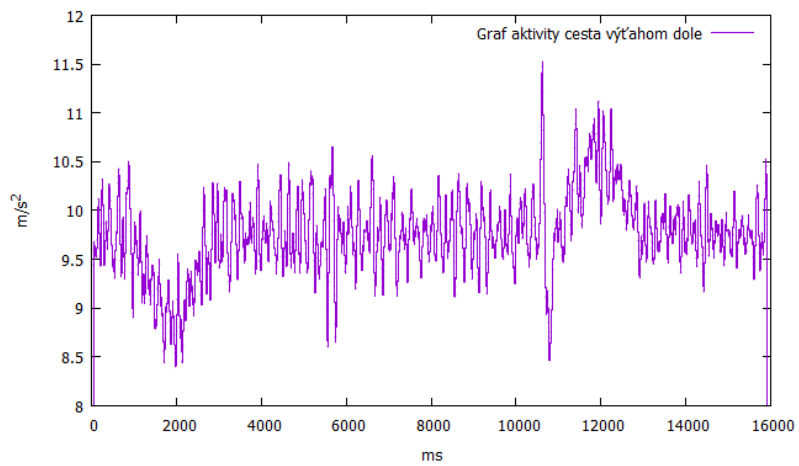

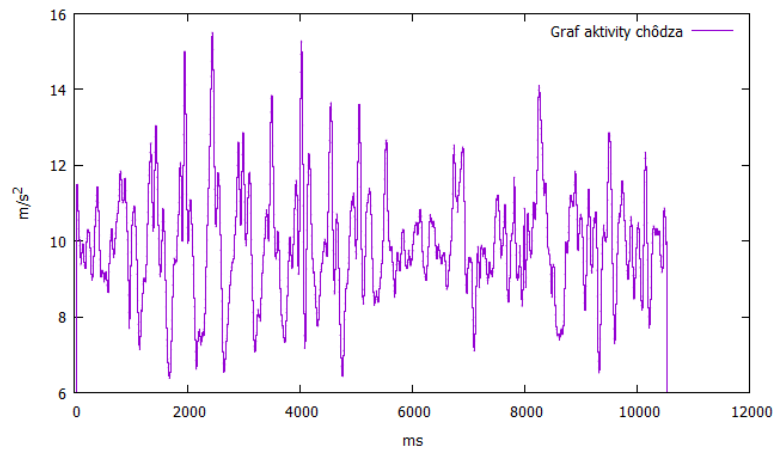
Vodorovná os grafu predstavuje veličinu času v mikrosekundách a horizontálna os zase veličinu celkového zrýchlenia v m/s^2 , ktoré sme vypočítali vzťahom:

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

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

Na nasledujúcich obrázkoch je ukážka vykreslenia dát akcelerometra pre niektoré z našich aktivít. Medzi jednotlivými grafmi si môžeme všimnúť rozdiely ako napríklad pri grafoch cesty výt'ahom nahor a nadol, kde je vidieť počiatočné a koncové výkyvy zrýchlenia pri rozbíhaní a zastavovaní výt'ahu, ktoré sú na pohľad zrkadlovo obrátené.

¹Zdroj: <http://javaplot.panayotis.com>



Obr. 5,6 a 7: Ukážka dát aktivít chůdza a cesta výtahom v oboch smeroch.

4 Implementácia metód na rozpoznávanie aktivity užívateľa

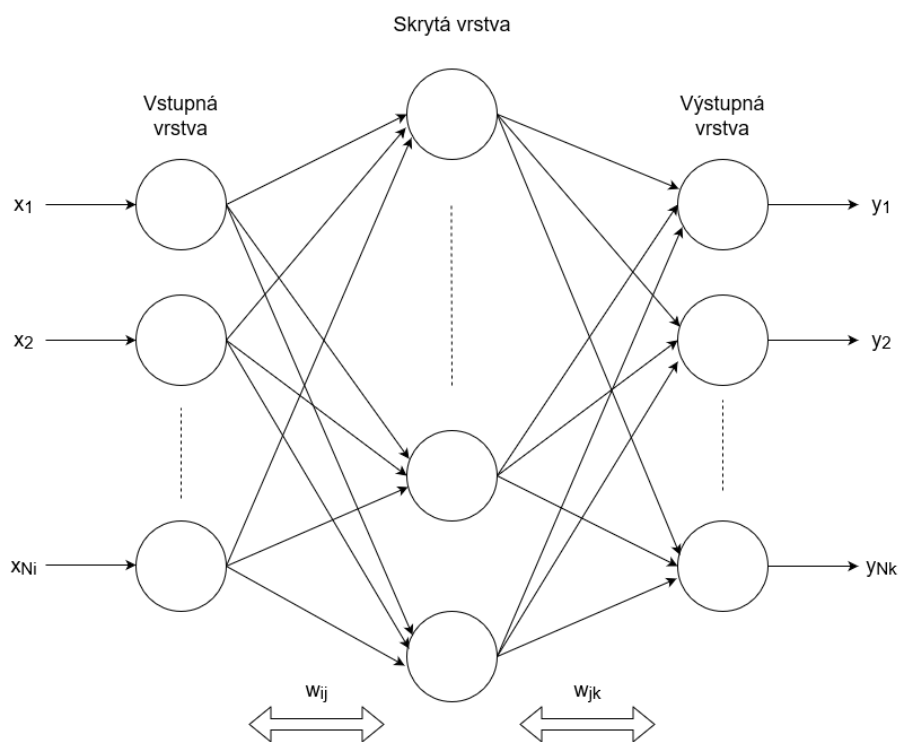
V tejto kapitole sú podrobne popísané implementované metódy a postupy na rozpoznávanie aktivity užívateľa.

4.1 Neurónová sieť

Umelá neurónová sieť je matematický výpočtový model, ktorý je inšpirovaný procesmi spracovania informácií neurónových sietí v ľudskom mozgu. Základným prvkom stavebným prvkom neurónovej siete je neurón. Jedným z typov neurónov je tzv. perceptrón, ktorý berie niekoľko binárnych vstupov, x_1, x_2, \dots , a vráti jeden binárny výstup. Neuróny sú všeobecne usporiadané do jednej z troch typov vrstiev:

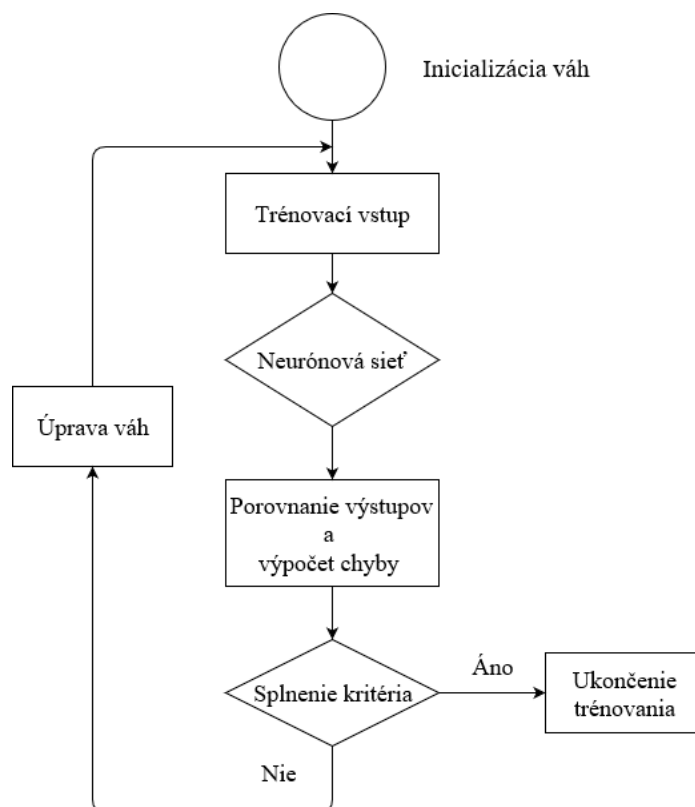
- vstupná vrstva,
- skryté vrstvy (ich počet môže byť rôzny),
- výstupná vrstva,

ktoré sú navzájom poprepájané spojeniami. Každé spojenie má svoju váhu w_{ij} , ktorá je nejaké reálne číslo vyjadrujúce mieru dôležitosti danej vstupnej hodnoty vzhľadom na výstup. Výstup neurónu, 0 alebo 1, je odvodený od toho, či je suma $\sum_j w_j x_j$ menšia alebo väčšia ako tzv. prahová hodnota. Tá je podobne ako váhy nejaké reálne číslo, ktoré je parametrom neurónu. Ukážku takejto neurónovej siete môžeme vidieť na nasledujúcom Obr. 8.



Obr. 8: Ukážka modelu neurónovej siete.

Ďalším krokom po skonštruovaní modelu neurónovej siete prichádza na rad proces učenia sa resp. tréovania. Ten zjednodušene prebieha tak, že sa na začiatku inicializujú hodnoty váh jednotlivých spojení medzi neurónmi a potom sa do siete vloží tréovací vstup a nechá sa prejsť sieťou. Následne sa porovnáva získaný výstup s očakávaným výstupom, vypočíta sa miera chyby a vzhľadom k tomu sa upravujú hodnoty váh jednotlivých spojení medzi neurónmi. Tento proces (viď. Obr. 9) sa cyklicky opakuje, až kým sa nedosiahne predom stanovené kritérium, ktorým je napríklad určitá miera presnosti, maximálny počet iterácií tréovania a iné.



Obr. 9: Proces učenia neurónovej siete.


4.2 Viacvrstvá perceptrónová neurónová sieť

Prvou metódou na rozpoznávanie aktivity je viacvrstvá perceptrónová neurónová sieť. Na jej implementáciu sme použili programovací jazyk Java a knižnicu Neuroph², 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.

²Zdroj: <http://neuroph.sourceforge.net/index.html>

4.2.1 Spracovanie vstupných dát

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 Obr. 10.



Obr. 10: Rozdelenie na jednotlivé okná.

Extrakcia 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 Math³ 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.

³Zdroj: <https://commons.apache.org/proper/commons-math/>

4.2.2 Štruktúra siete

Pri vytváraní modelu našej neurónovej siete sme sa stretli s viacerými premennými, ktoré môžu výrazne ovplyvniť jej správanie sa. Pri rozhodovaní sa aké hodnoty si stanovíme pre jednotlivé premenné sme kombinovali hodnoty, ktoré sa vyskytovali v prácach s podobnou problematikou, s tými nastaveniami, ktoré sme experimentálne testovali.

Jednou z najdôležitejších premenných bol počet skrytých vrstiev a počet neurónov v nich. Naš model obsahuje vstupnú vrstvu s 24 vstupnými neurónmi, z ktorých každá reprezentuje jeden z atribútov v jednom zázname nášho datasetu, jednu skrytú vrstvu s 30 neurónmi a výstupnú vrstvu so 6 neurónmi, ktoré reprezentujú počet rôznych aktivít, ktoré v rámci tejto práce chceme rozoznávať. Ako učiaci algoritmus, ktorý slúži na úpravu váh používame algoritmus backpropagation. Rozdelenie datasetu na tréningovú a testovaciu sadu robíme v pomere 70% tréningová a 30% testovacia sada, čo je všeobecne zaužívané. Ostatné premenné ako napríklad učiaci pomer, maximálna veľkosť chyby alebo maximálny počet iterácií pri tréningu siete si môžeme ľubovoľne nastavovať podľa potreby.

5 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.

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.