

Indoor lokalizácia používateľa smartfónu s využitím neurónových sietí

Analýza a návrh riešenia

Patrik Rojek

11m, 2019 – 2020

Abstrakt. Práca sa zaoberá skúmaním využitia neurónových sietí na rozpoznávanie aktivity užívateľa smartfónu v indoor prostredí. Hlavným cieľom práce je navrhnúť samostatné alebo čiastkové metódy založené na strojovom učení využívajúce senzory smartfónu alebo iného zariadenia s cieľom zlepšiť presnosť indoor lokalizácie a následne tieto metódy implementovať a overiť ich použiteľnosť a presnosť.

Kľúčové slová: indoor lokalizácia, indoor prostredie, neurónové siete, strojové učenie, smartfón, senzor

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 zotrvačiek 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.

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.

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 považovať jeden krok ako „základná“ jednotka, ktorá sa ale

pri každej z aktivít inak prejaví v zaznamenaných dátach. Napríklad, beh v porovnaní s chôdzou bude mať vyššiu frekvenciu krokov v závislosti od času, kráčanie po schodoch sa od chôdze odlišuje v zmene vertikálnej pozície subjektu, či už smerom nahor alebo nadol, čo sa prejaví aj na dátach zo senzorov.

Prvým cieľom práce je preskúmať využitie neurónových sietí na rozpoznávanie aktivity užívateľa smartfónu v indoor prostredí. Týmto problémom som sa začal zaoberať už pri mojej bakalárskej práci.

Výsledkom mojej bakalárskej práce bol návrh a implementácia dvoch metód na rozpoznávanie aktivít s použitím zabudovaných senzorov v smartfóne, konkrétne akcelerometra. Rozpoznávaných bolo sedem aktivít: státie, sedenie, chôdza, chôdza po schodoch smerom nahor, chôdza po schodoch smerom nadol, cesta výťahom smerom nahor a nadol. Prvou metódou bolo použitie viacvrstvovej perceptrónovej neurónovej siete, s ktorou sme pri rozpoznávaní siedmich nami určených aktivít dosiahli priemernú úspešnosť nad 95%. Ako druhú metódu sme použili LSTM (Long Short-Term Memory), ktorá patrí medzi rekurentné neurónové siete a dosiahli sme úspešnosť 92%. Výsledky získané použitím implementovaných metód ukázali, že vieme s dostatočnou presnosťou rozpoznávať aktivitu užívateľa smartfónu, a preto ich možno ďalej využiť aj v iných oblastiach napr. v oblasti indoor navigácie.

2 Základné pojmy

2.1 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 využívajú iné druhy signálov ako napríklad Wi-Fi, Bluetooth, Li-Fi (využíva svetlo na prenos dát a polohy medzi zariadeniami), 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 berie do úvahy aj aktuálne poschodie a zmena poschodia, či už prostredníctvom schodov, výťahu alebo eskalátora.

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 staniách, letiskách a pod. a fungujú tak, že zobrazujú navigačnú trasu alebo navigačné značky vedúce k cieľovému miestu. Pri indoor navigácii s automatickým určovaním polohy sa pozícia zvyčajne vypočítava priamo na smartfóne používateľa prakticky v reálnom čase.

Jedným z hlavných využití rozpoznanej aktivity na lokalizovanie používateľa v indoor prostredí je spresnenie určenia aktuálnej polohy a pohybu subjektu vzhľadom na okolité prostredie. Uvažujme napríklad takú situáciu, kde používateľ od svojej aktuálnej pozície urobí desať krokov daným smerom. Normálnou chôdzou s priemernou


dĺžkou kroku 0,6 metra použivateľ prejde vzdialenosť 6 metrov. Ak by však urobil desať krokov chôdzou po schodoch so šírkou jedného schodu 0,3 metra, prejdená vzdialenosť od štartovacej pozície by bola len 3 metre, čo by bol výrazný rozdiel oproti normálnej chôdzi, a ak by sme tieto dva rozdielne scenáre nerozoznávali, nastala by pri ďalšej navigácii výrazná odchýlka pri odhade novej pozície. Podobne, aj vďaka rozpoznaniu aktivít ako cesta výtahom alebo chôdza po schodoch vieme povedať, že pravdepodobne nastala zmena poschodia v rámci budovy, a teda musíme brať do úvahy napríklad iné topografické členenie nového poschodia a pod.

V rámci metodiky práce využívame prístupy strojového učenia pri implementácii metód rozpoznávania aktivity použivateľa smartfónu v indoor prostredí. Tieto metódy priamo súvisia a dajú sa následne využiť v indoor navigácii.

2.2 Rozpoznávanie aktivity

Na rozpoznávanie aktivity uživateľa existujú v súčasnosti rôzne aplikácie v oblastiach navigácie, sociológie, medicínskych službách, kde sa využívajú na monitorovanie fyzickej aktivity pacienta ako súčasť liečby, na diaľkové sledovanie pacientov so zdravotným postihnutím alebo seniorov a ďalších oblastiach. Existujú rôzne vyhodnocovacie metódy, z ktorých niektoré podrobnejšie opisujeme v kapitole 2. Hlavnou myšlienkou týchto aplikácií je na základe získaných dát rozpoznať akú aktivitu použivateľ vykonáva. Práca spojená s rozpoznávaním ľudských aktivít je kombináciou spracovania údajov a ich následnej klasifikácie.

Proces rozpoznávania aktivity prebieha väčšinou tak, že keď použivateľ vykonáva fyzickú aktivitu, akou je napríklad chôdza, počas používania smartfónu je možné zaznamenávať hodnoty zo zabudovaných senzorov smartfónu, čo sa nazýva zhromažďovanie vzorkových dát. Tieto namerané dáta sa následne podľa potreby filtrujú alebo aj inak predbežne spracovávajú a upravujú na požadovaný formát. Potom sa z nich dá extrahovať unikátna sada vlastností (features) 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.



Obr. 1: Schéma architektúry systému na rozpoznávanie aktivity.

2.3 Sensory smartfónu


Sensory sú zariadenia, ktoré merajú hodnotu fyzickej energie a konvertujú ju na signál. Smart zariadenia, medzi ktoré patria aj smartfóny, už v dnešnej dobe bežne obsahujú širokú ponuku senzorov spomedzi desiatok rôznych existujúcich druhov senzorov, ktoré merajú orientáciu, pohyb, svetlo a iné environmentálne podmienky. Smartfóny majú jednak hardvérové sensory, ktoré sú fyzicky prítomné v zariadení a priamo merajú vlastnosti okolitého prostredia, ako aj softvérové sensory, ktoré sú virtuálne. Softvérové sensory zaznamenávajú vstupy z jedného alebo viacerých hardvérových senzorov na následné výpočty. Sensory sa rozdeľujú do skupín podľa rôznych kritérií.

Jedným z možných delení senzorov podľa [6] je:

- *Pohybové sensory* – merajú akceleračné a rotačné sily pozdĺž troch osí a táto kategória zahŕňa akcelerometre, gravitačné sensory, gyroskopy, a rotačné vektorové sensory.
- *Polohové sensory* – merajú fyzickú polohu zariadenia a patria sem snímače orientácie a magnetometre.
- *Enviromentálne sensory* – 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 sensory, ktoré sa používajú v oblasti rozpoznávania aktivity a navigácie patria:

- **Akcelerometer** - patrí medzi hardvérové sensory 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 sensor, 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.


2.4 Neurónová sieť

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

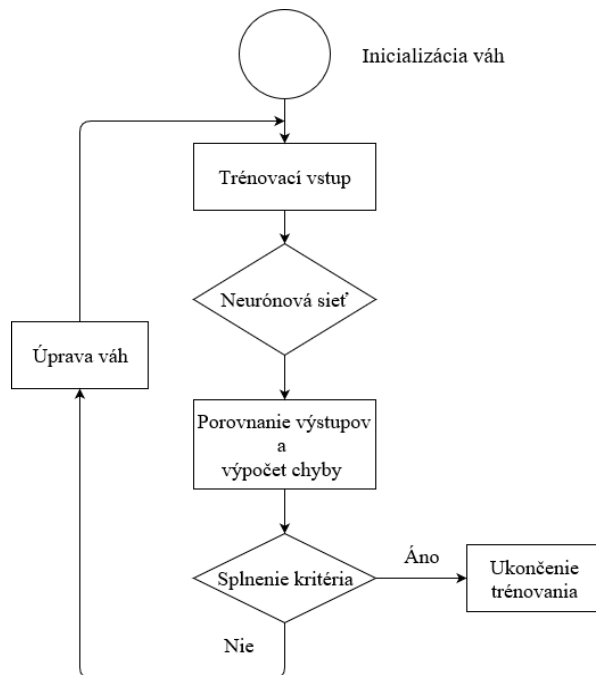
- vstupná vrstva
- skryté vrstvy (ich počet môže byť rôzny)
- výstupná vrstva

Tieto vrstvy sú navzájom poprepájané spojeniami. Každé spojenie má svoju váhu w_{ij} , ktorá je reálnym číslom, vyjadrujúcim mieru dôležitosti danej vstupnej hodnoty vzhľadom na výstup. Zvyčajne je každý vstup neurónu zvlášť vážený a suma $\sum_j w_j x_j$ prechádza nelineárnou funkciou známou ako aktivačná funkcia alebo prenosová funkcia. Aktivačné funkcie majú svoju tzv. prahovú hodnotu, na základe ktorej sa ešte upravujú hodnoty vo výstupe neurónu na 0 alebo 1, vzhľadom k tomu, či je daná hodnota menšia alebo väčšia ako nastavená prahová hodnota. Takto získame výstup neurónu, ktorý sa potom môže ďalej šíriť do ďalších neurónov v neurónovej sieti. Ukážku takejto neurónovej siete môžeme vidieť na Obr. 3.

Ďalším krokom po skonštruovaní modelu neurónovej siete je proces strojového učenia sa, resp. tréningu. Ten zjednodušene prebieha tak, že sa na začiatku inicializujú hodnoty váh jednotlivých spojení medzi neurónmi, a potom sa do siete vloží tréningový vstup (v našom prípade označené dáta, ktoré sme získali z aplikácie a aj externého datasetu) 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 znázornený na Obr. 4 sa cyklicky opakuje, až kým sa nedosiahne predom stanovené kritérium, ktorým je napríklad určitá miera presnosti, maximálny počet iterácií tréningu a iné.



Obr. 3: Ukážka modelu neurónovej siete



Obr. 4: Proces učenia neurónovej siete

Rozpoznávanie aktivity je netriviálny problém, pretože nevieme jednoducho definovať univerzálne pravidlá na klasifikáciu aktivít. Príkladom na túto netriviálnosť sú rôzne faktory okolitého prostredia (rozdielne výšky schodov, výťahy a iné) alebo aj zašumené dáta, ktoré boli zaznamenané rôznymi ľuďmi s rôznymi zariadeniami a pod. Práve preto je na riešenie tohto problému výhodné použiť neurónové siete.

3 Prehľad existujúcich riešení na rozpoznávanie aktivity

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. 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

4 Prehľad existujúcich metód určovania polohy v indoor prostredí s využitím smartfónu

Článok [4] poskytuje prehľad najvýznamnejších existujúcich metód určovania polohy v indoor prostredí s využitím smartfónu. V súčasnosti však neexistuje žiadna jediná technológia, ktorá by poskytovala spoľahlivú indoor lokalizáciu. Medzi technológie, ktoré sa potenciálne dajú implementovať v smartfónoch, patria:

- využívanie vysokofrekvenčných rádiových (RF – radio frequency) signálov, buď takých, ktoré už existujú, ako sú bezdrôtové lokálne siete (WLAN) alebo mobilné siete, alebo signály generované novou a špecializovanou infraštruktúrou (RFID / NFC, Bluetooth)
- určovanie polohy pomocou snímania odtlačkov magnetických polí

- navigáciu pomocou mapy s využitím plánov budov a pomocou samostatných senzorov
- využitie samostatných senzorov: trojosový akcelerometer, trojosový gyroskop, trojosový magnetometer, barometer

Žiadna z týchto technológií nie je kompletným riešením na vyriešenie všetkých potrieb indoor lokalizačných systémov na súčasných zariadeniach, ktoré sú široko dostupné na trhu. Rôzne takéto zariadenia majú svoje výhody a nevýhody, ktoré závisia od charakteru každej technológie.

Medzi typické úlohy indoor navigácie pomocou smartfónu patrí lokalizácia ľudí a miest vo verejných budovách, ako sú univerzity, nákupné strediská a letiská, na športových podujatiach, konvenciách atď., monitorovanie detí a starších ľudí a automatické označovanie príspevkov a obrázkov. Na splnenie týchto požiadaviek musí byť presnosť lokalizácie v typickej kancelárskej budove na úrovni určenia správnej miestnosti a taktiež podlažie musí byť správne identifikované. V prípade veľkých otvorených priestorov, ako sú letiská a nákupné strediská, postačuje presnosť niekoľkých metrov na vytvorenie vizuálneho kontaktu a nájdenie požadovaného miesta, napríklad letiskovej brány. Pre niektoré aplikácie, ako je navigácia v obchode alebo prehliadka múzeí, je potrebná lepšia presnosť určovania polohy. To sa dá dosiahnuť polohovaním na základe BLE, keď sú vysielače signálu husto umiestnené v požadovaných oblastiach.

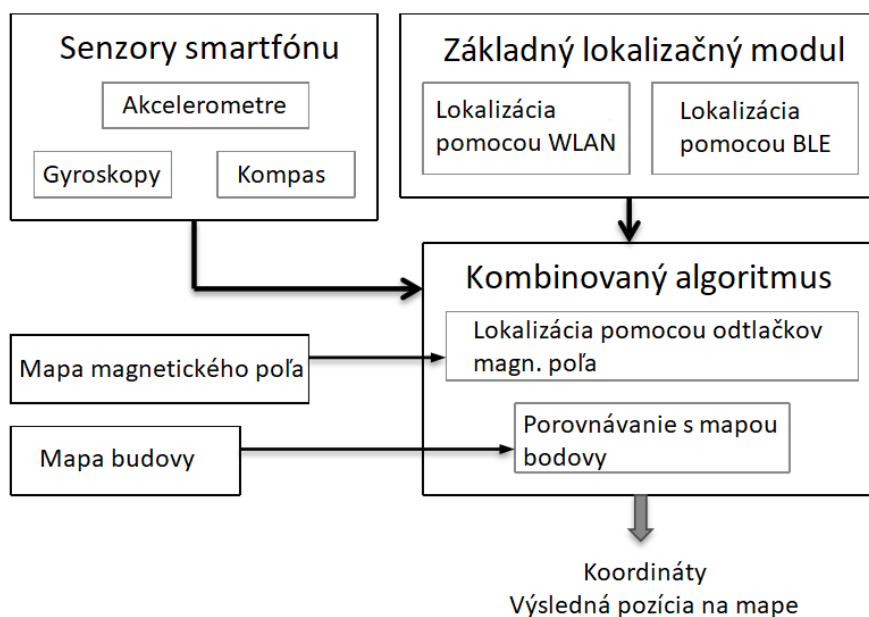
V súčasnosti väčšina smartfónov využíva lokalizáciu na báze WLAN, ktoré obvykle uspokojuje požiadavky na presnosť polohy v oblastiach bohatých na smerovače WLAN. Presnosť však významne závisí od hustoty WLAN smerovačov a od kvality rádiovkej mapy, ktorá sa s postupom času obvykle zhoršuje a musí sa pravidelne aktualizovať. Zlepšenie určovania polohy založeného na WLAN / BLE sa dá dosiahnuť, ak sa použijú ďalšie senzory a zdroje informácií, napríklad samostatné snímače, ktoré zlepšujú presnosť a spoľahlivosť medzi aktualizáciami pozícií založenými na WLAN a počas medzier v pokrytí WLAN / BLE.

Ďalšími bežne používanými metódami na zlepšenie polohy sú porovnanie s mapou (map-matching) a určovanie polohy pomocou snímania odtlačkov magnetických polí. Môžu sa skombinovať s WLAN / BLE a senzormi, aby sa zvýšila presnosť polohy. Polohovanie založené na magnetickom poli je koncepčne podobné terénnym navigačným systémom vo vojenských lietadlách a ponorkách, v ktorých sa odhadovaná pozícia určí na základe porovnania údajov s mapou; pri lokalizácii pomocou magnetického poľa v indoor prostredí sú miestne deformácie magnetického poľa spôsobené hlavne oceľou v konštrukcii stavieb a budov.

Hlavné súčasti a tok údajov v polohovacom systéme inteligentných telefónov sú znázornené na obr. 5. Tieto technológie spĺňajú požiadavky na masové zavádzanie na smartfónoch hromadného trhu, avšak nie všetky tieto komponenty musia byť v lokalizačnom systéme nevyhnutne prítomné. Možné kombinácie technológií pre vnútornú navigáciu zahŕňajú:

- WLAN (mapa sa používa iba na účely zobrazenia)
- WLAN a senzory
- WLAN a mapa budovy na map-matching
- WLAN, map-matching a senzory

Určovanie polohy pomocou snímania odtlačkov magnetických polí a lokalizácia na základe BLE môžu byť pridané do ktorejkoľvek z týchto kombinácií. V tejto kapitole si predstavíme niektoré z nich.



Obr. 5: Hlavné súčasti indoor lokalizačného systému pre smartfóny

4.1 Polohovacie systémy založené na WLAN a BLE (Bluetooth Low Energy)


Prístupové body WLAN (AP) vysielajú rámce, ktoré zahŕňajú MAC adresu prístupového média (AP), spravidla každých 100 ms na oznámenie ich prítomnosti v určitej oblasti. Mobilné uzly prijímajú tieto signály a môžu identifikovať AP podľa svojej MAC adresy. Aj keď sieť WLAN nebola navrhnutá na určovanie polohy, dá sa použiť na odhad polohy používateľa využitím meraní sily prijímaného signálu (RSS – received signal strength). Táto technológia je veľmi prítlačlivá pre určovanie polohy, pretože prístupové body WLAN sú ľahko dostupné vo väčšine budov a každý smartfón má pripojenie k sieti WLAN.

Určovanie polohy WLAN si však vyžaduje vytvorenie a údržbu rádiovkej mapy, čo je časovo náročná a náročná práca. Použitie crowdsourcingu (na zber údajov) pre rádiovú mapu je zložité, ak nie je v interiéri k dispozícii detekcia, ktorá je bežne nedostupná, a dáta nie je možné získať v pozadí na užívateľských zariadeniach. Implementácia lokalizácie na základe WLAN pomocou smartfónu je zvyčajne založená na

metódach RSS. Pretože namerané údaje RSS sú veľmi zašumené, iba dvojfázové prístupy, ktoré zahŕňajú predbežnú fázu zhromažďovania údajov do tréningovej vzorky, môžu poskytnúť požadovanú presnosť lokalizácie.

4.1.1 Lokalizácia pomocou RSS

Základným prístupom k určovaniu polohy je trilaterácia (obr. 6). Táto technika odhaduje umiestnenie mobilného uzla zmeraním jeho vzdialeností k niekoľkým referenčným bodom. Najprv sa merania RSS prevedú na vzdialenosť od mobilného uzla k AP, potom sa umiestnenie uzla vypočíta pomocou geometrie kruhov. V prípade lokalizácie založenej na WLAN však metóda trilaterácie neposkytuje presné výsledky kvôli chybám, ktoré vznikajú pri prevode meraní RSS na vzdialenosť. Tento problém je obzvlášť závažný v indoor prostrediach, kde signály WLAN môžu byť ovplyvnené stenami a zoslabené telami ľudí. Navyše, orientácia smartfónu ovplyvňuje aj merania RSS.



Obr. 6: Hlavné súčasti indoor lokalizačného systému pre smartfóny

Alternatívou k explicitnej konverzii merania sily signálu na vzdialenosť je porovnanie meraní RSS s rádiovou mapou. Tento prístup na rozpoznávanie vzoru sa nazýva lokalizácia pomocou odtlačkov signálu (fingerprinting). Existujú dve fázy pre lokalizáciu pomocou odtlačkov signálu: offline fáza a online fáza.

V offline fáze sa namerajú hodnoty RSS („odtlačky prstov“) na rôznych kalibračných miestach v celej záujmovej oblasti a zaznamenávajú sa do databázy. Online fáza je určenie polohy používateľa, keď sa porovnávajú merania RSS na mobilnom zariadení so zaznamenanými odtlačkami prstov z databázy.

Sada „počutých“ prístupových bodov na určitom mieste počas online fázy sa môže líšiť od súboru prístupových bodov uložených v rádiovkej mape, pretože niektoré prístupové body sa dajú odstrániť a nastavenia nových pridaných prístupových bodov (AP) sa môžu zmeniť. Preto je proces výberu AP zahrnutý do online lokalizácie. Miesto, ktoré najlepšie zodpovedá pozorovaným silám signálu, sa považuje za aktuálnu polohu používateľa.


Problémom pri fingerprintingu je, že staršie zaznamenané hodnoty RSS sa môžu dosť líšiť od aktuálnych hodnôt z dôvodu zmien prostredia a nastavení v prístupových bodov. Odstránenie alebo pridanie nových prístupových bodov v oblasti záujmu by si vyžadovalo úpravy v databáze. Na merania RSS môže mať vplyv aj typ a model mobilného zariadenia. Napriek týmto obmedzeniam môže fingerprinting dosiahnuť primeranú presnosť a stala sa hlavným prístupom k lokalizácii pomocou WLAN.

Fingerprinting algoritmy môžu byť deterministické alebo pravdepodobnostné. Pri deterministických sa zistí jedna alebo niekoľko pozícií, ktoré najlepšie zodpovedajú pozorovaným hodnotám RSS so zaznamenanými odtlačkami signálov. Pri pravdepodobnostných algoritmoch sú hodnoty sily signálu vyjadrené ako rozdelenie pravdepodobnosti a algoritmus vypočíta pravdepodobnosť polohy používateľa na základe online meraní a databázy RSS.

4.1.2 Radio mapy

Rádiová mapa (obr. 7) sa vytvára ako súčasť offline fázy pri učení a obsahuje namerané hodnoty RSS na známych miestach nazývaných kalibračné body. Zhromažďovanie údajov potrebných na tvorbu rádiových máp je však časovo náročný a pracný proces. Generovanie rádiovkej mapy začína rozdelením skúmanej oblasti do buniek na základe plánu podlažia budovy. Pre každú bunku sa RSS signál prenášaný rôznymi AP meria počas určitého časového obdobia v kalibračnom bode a ukladá sa do databázy rádiových máp.

Hodnoty RSS môžu byť ovplyvnené orientáciou alebo umiestnením smartfónu vzhľadom na telo používateľa počas meraní, heterogenitou zariadenia a tiež hustotou ľudí v budove v tejto dobe, pretože ľudské telo silne tlmí signál. Presnosť rádiovkej mapy sa časom zhoršuje v dôsledku variácii WLAN signálov jednotlivých AP a ďalších zmien prostredia, ako je napríklad poloha nábytku a stien. Preto sa musia periodicky zbierať nové odtlačky signálov, aby sa zabezpečila aktuálnosť rádiovkej mapy.



Obr. 7: Ukážka rádio mapy

4.1.3 Použitie algoritmov strojového učenia

Na lokalizáciu vieme využiť aj Support vector machines (SVM), techniku na klasifikáciu údajov, štatistickú analýzu a strojové učenie, ktorá sa nedávno používa na určovanie polohy pomocou RSS fingerprinting-u. SVM modely klasifikujú údaje tak, že určia najlepšiu hyperrovinu, ktorá separuje všetky body jednej triedy od bodov druhej triedy. Najlepšou hyperrovinou sa stane tá, ktorá má najväčší rozdiel medzi týmito dvoma triedami. Rozdielom chápeme maximálnu šírku dvoch rovnobežiek rovnobežných s hyperrovinou, medzi ktorými sa nenachádzajú žiadne dátové body z oboch uvažovaných tried. Klasifikáciou databázy odtlačkov signálov môžeme získať optimálne najbližšie susedné body. Keď sa SVM aplikuje na lokalizáciu pomocou RSS, inferenčný model sa musí vybudovať vopred. SVM preto nerieši najväčšiu nevýhodu tradičnej lokalizácie pomocou technológie RSS súvisiace s adaptabilitou na zmeny okoliťného prostredia.

4.2 Lokalizácia pomocou magnetických polí

Na lokalizáciu pomocou magnetických polí sa používa mapa distribúcie magnetického poľa vo vnútri budov na určovanie polohy v indoor prostredí. Poruchy zemského magnetického poľa v indoor prostredí sú spôsobené hlavne kovovou štruktúrou budov. Prístup k určovaniu polohy pozostáva z dvoch fáz: z offline mapovania meraní magnetického poľa na známych miestach a online určovania polohy porovnaním meraného magnetického poľa s odtlačkami signálov z databázy. Na rozdiel od lokalizácie založenej na WLAN alebo BLE poskytuje lokalizácia pomocou magnetického poľa iba lokálne určovanie polohy kvôli svojej priestorovej nejednoznačnosti. Najväčšou výhodou tohto prístupu je to, že magnetické pole je všade, je relatívne stabilné, a preto nie je potrebná žiadna predinštalovaná infraštruktúra. Existujú však aj závažné nevýhody:

- jeden odtlačok signálu pozostáva iba z malého počtu parametrov, najviac z troch, ale zvyčajne z dvoch alebo dokonca jedného;
- gradient magnetického poľa môže byť niekedy veľmi strmý;
- môžu sa vyskytnúť prerušované magnetické interferencie.


Merania vektora magnetického poľa pochádzajú z 3D magnetometra smartfónu v súradnicovom systéme zariadenia. Pretože pozícia smartfónu sa môže voľne meniť, je potrebná znalosť transformácie medzi zariadením a okolitým prostredím. Presné vypočítanie 3D postoja smartfónu je náročná úloha, pretože merania sú nespoľahlivé, keď sú veľké interferencie magnetického poľa. V mnohých scenároch reálneho života je smer gravitácie (meraný pomocou akcelerometrov) jedinou zložkou pólu, ktorú je možné vypočítať, čím sa znižuje počet parametrov odtlačkov signálov na dva. Ak sa nedá vypočítať ani smer gravitácie, potom sa ako jediný parameter môže použiť iba veľkosť intenzity magnetického poľa, pretože jej veľkosť je nezávislá od polohy magnetického senzora. Malý rozmer odtlačkov signálov spôsobuje, že fingerprinting magnetického poľa nie je spoľahlivý a priestorovo nejednoznačný. Okrem toho stanovuje aj prísne požiadavky na tvorbu databázy odtlačkov signálov. Veľké gradienty magnetického poľa sú výhodné pre lokalizáciu, avšak to si vyžaduje mapu magnetického poľa s veľmi vysokým rozlíšením, čím sa efektívne mapovanie magnetického poľa stane

jednou z najväčších výziev pre tento prístup. Medzi ďalšie výzvy týkajúce sa používania magnetického poľa na určovanie polohy pomocou smartfónov patrí rozmanitosť zariadení a scenáre použitia a výrazná variabilita magnetického poľa s nadmorskou výškou. Aj údaje z toho istého zariadenia sa líšia v rôznych nadmorských výškach. Preto, aby sa dosiahla dobrá presnosť, mala by byť mapa magnetického poľa trojrozmerná.

4.3 Lokalizácia s využitím mapy indoor prostredia

Myšlienka využívania stavebnej geometrie na zníženie chýb v polohe a smere v autonómnych lokalizačných systémoch sa v posledných rokoch intenzívne využíva. V prípade indoor navigácie predstavujú plány podlaží v budovách obmedzenia, ktoré obmedzujú pohyb. Napríklad ľudia nemôžu chodiť cez steny a podlažia sa môžu meniť iba prostredníctvom schodov alebo výťahov. Cieľom navigácie pomocou mapy je využiť predchádzajúce informácie obsiahnuté v mapách alebo stavebných plánoch na zlepšenie presnosti určovania polohy. Ak je k riešeniu na báze WLAN alebo BLE k dispozícii aj indoor mapa, môže to zlepšiť presnosť určovania polohy. V súčasnosti existujú tri prístupy k navigácii v interiéri s mapami, ktoré je možné implementovať na smartfónoch:

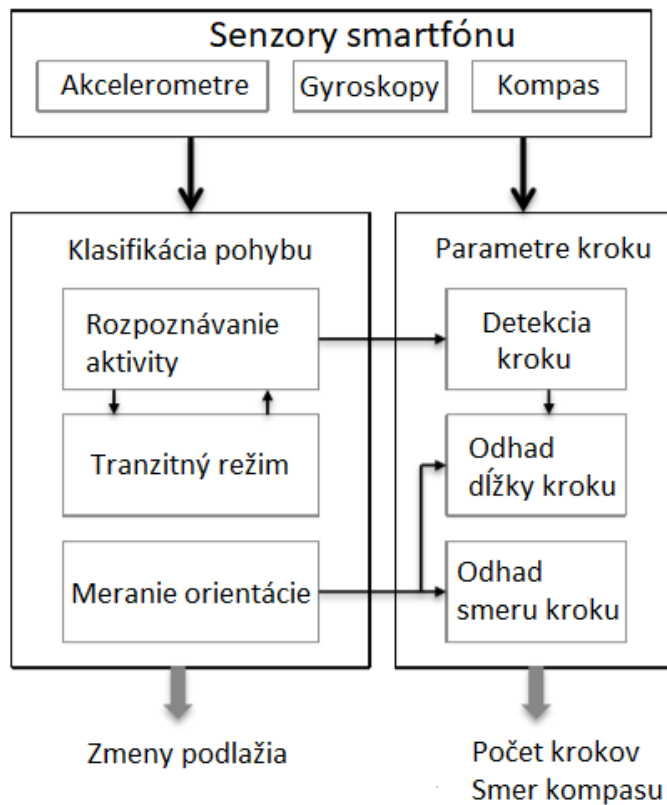
- pravdepodobnostné mapovanie založené na filtrácii častíc (numerické riešenie Bayesovskej filtračnej rovnice pomocou algoritmov známych ako particle filters) pomocou obmedzení okolitých stien
- topologické mapovanie na základe reprezentácie plánu budovy pomocou uzlov a hrán (obr. 8),
- zníženie chyby smerovania v porovnaní s kardinálnym smerovaním budovy, t.j. orientáciou.



Obr. 8: Ukážka uzol-hrana mapy budovy. Hrany sú znázornené modrými čiarami.

odhadu dĺžky a smeru kroku, klasifikácia pohybu, detekcia tranzitného režimu a detekcia zmeny podlažia vo viacpodlažných budovách. Tieto úlohy sa vykonávajú pomocou takzvaného „pedestrian dead reckoning“ algoritmu (PDR), ktorý počíta polohu integráciou vektorov posunu, ktoré predstavujú kroky. Ak sa nezistia žiadne kroky, predpokladá sa, že systém je nehybný/stacionárny. Výkon PDR je pomerne robustný vzhľadom na kvalitu snímača, vďaka čomu je vhodný na implementáciu do smartfónov. Každý systém PDR vykonáva tieto úlohy:

- Počítanie krokov alebo segmentácia krokov
- Odhad dĺžky kroku
- Odhad smeru kroku



Obr. 10: Hlavné úlohy, ktoré môžu byť vykonávané s využitím senzorov smartfónu

5 Activity Recognition API od Google-u

V rámci štúdia dostupnej literatúry a technológii, ktoré by sme potenciálne vedeli v diplomovke využiť, sme narazili aj na API na rozpoznávanie aktivity užívateľa smartfónu, ktoré je dostupné od Google-u. Activity Recognition API [5] je postavené na senzoch, ktoré sú dostupné v smartfóne. Sensory zariadení poskytujú informácie o tom, čo používatelia v súčasnosti robia. Avšak s desiatkami signálov z viacerých senzorov a malými odchýlkami v tom, ako ľudia robia veci, nie je ľahké zistiť, čo používatelia robia.

Rozhranie API na rozpoznávanie aktivít automaticky zisťuje činnosti pravidelným čítaním krátkych impulzov údajov senzorov a ich spracovaním pomocou modelov strojového učenia. Na optimalizáciu zdrojov môže rozhranie API zastaviť podávanie správ o činnosti, ak bolo zariadenie určitý čas stále, a používa senzory s nízkou spotrebou na obnovenie podávania správ, keď zistí pohyb.

Minimálne požiadavky potrebné pre použitie tohto API sú:

- minimálna API verzia 9 pre reálne zariadenia a 17 pre emulátory
- Android zariadenie s verziou Android 2.3 a vyššou, ktorý obsahuje aj Google Play Store

Pomocou tohto API sa dajú detegovať nasledujúce aktivity, z ktorých každá zahŕňa aj úroveň pravdepodobnosti :

- IN_VEHICLE – vo vozidle,
- ON_BICYCLE – na bicykli,
- ON_FOOT - pešo,
- RUNNING - beh,
- WALKING - chôdza,
- STILL – zariadenie je v pokoji,
- TILTING – zariadenie sa nakláňa,
- UNKNOWN – neznáma aktivita.

6 Implementácia navrhnutých metód

V rámci tejto práce sme sa chystali použiť viacero užitočných a hlavne odlišných datasetov na viacerých modeloch neurónových sietí. V tejto kapitole sú popísané jednotlivé datasety, postupy pri predspracovaní týchto dát pred tým ako sme ich mohli

použiť na vstupoch našich modelov a popis jednotlivých navrhnutých implementovaných metód.

6.1 Detekcia chôdze

Prvou metódou na rozpoznávanie aktivity je viacvrstvová perceptrónová neurónová sieť, pomocou ktorej sme chceli rozpoznávať aktivitu chôdze od ostatných uvažovaných aktivít. Na jej implementáciu sme použili programovací jazyk Java a knižnicu Neuroph¹, ktorá slúži na implementáciu mnohých známych architektúr neurónových sietí.

Keďže v rámci rozpoznávania aktivity užívateľa pri indoor navigácii nevieme z jednej vstupnej hodnoty určiť vykonávanú aktivitu, tak neurónová sieť potrebuje na vstupe viacero hodnôt. Naším zámerom pri použití tejto metódy bolo experimentálne zistiť, či sa dá s dostatočnou presnosťou určiť o akú aktivitu ide, keď na vstupe dostaneme iba krátky izolovaný úsek dát o dĺžke maximálne pár sekúnd.

Chceli sme si zvoliť časový úsek konkrétnej dĺžky, pre ktorý sa z dát vypočítajú vybrané charakteristické vlastnosti. Tieto údaje sa už ďalej samostatne, bez nejakého predošlého kontextu alebo spojenia s údajmi z predošlého úseku, posunú neurónovej sieti za účelom klasifikácie aktivity.

Uvedený časový úsek je vhodné mať čo možno najkratší pre zníženie času potrebného na poskytnutie odhadu aktuálne vykonávanej aktivity, ale zároveň dostatočne dlhý na to, aby sme v ňom vedeli obsiahnuť charakteristické črty danej aktivity.

Podľa [17] presnosť detekcie chôdze môžu výrazne ovplyvniť nasledujúce faktory:

- umiestnenie zariadenia
- orientácia zariadenia
- návyky konkrétneho používateľa pri chôdzi
- veľkosť/šírka posuvných okien pri spracúvaní dát
- snímacia frekvencia senzorov (optimálna frekvencia 50-200Hz)

6.1.1 Dataset Heterogeneity Activity Recognition

Tento externý dataset sme získali z UCI Machine Learning Repository², online repozitára pre datasey využívané na účely strojového učenia, aby sme mali dostatočne veľký dataset potrebný pre potreby implementovaných metód na rozpoznávanie aktivity používateľa smartfónu.

Externý dataset obsahoval merania zo senzorov akcelerometra a gyroskopu zo smartfónu a smart hodín pre nasledujúce aktivity: jazda na bicykli, sedenie, státie, cesta po schodoch smerom nahor aj nadol. Dáta boli nahrávané pomocou ôsmich smartfónov a deviatich používateľov.

V rámci našej práce sme z tohto datasetu využili dáta z akcelerometra a aj z gyroskopu smartfónu pre všetky spomenuté aktivity okrem jazdy na bicykli, keďže sa

¹Zdroj: <http://neuroph.sourceforge.net/index.html>

²Zdroj: <http://archive.ics.uci.edu/ml/datasets/heterogeneity+activity+recognition>

zaoberáme rozpoznávaním aktivít v indoor prostredí. Použité dáta externého datasetu mali celkovú dĺžku vyše 24 hodín. Dáta pre aktivity cesta výtahom smerom nahor a nadol, ktoré sa v externom datasete nenachádzali, sme doplnili našimi vlastnými nazeranými dátami.

6.1.2 Ukážka zaznamenaných dát


Trojosový akcelerometer slúži na meranie polohy, pohybu, náklonu, nárazov, vibrácií a zrýchlenia (jednotka zrýchlenia v m/s^2) na každej z troch osí. Namerané zrýchlenie zahŕňa nameranú zmenu rýchlosti spolu s gravitačným zrýchlením.

Na nasledujúcich obrázkoch grafov (viď. Obr. 11 a Obr. 12) je ukážka vykreslenia dát akcelerometra každej z našich aktivít. Vodorovná os grafov predstavuje veličinu času v milisekundách a horizontálna os zase veličinu celkového zrýchlenia v m/s^2 , ktoré sme vypočítali vzťahom:

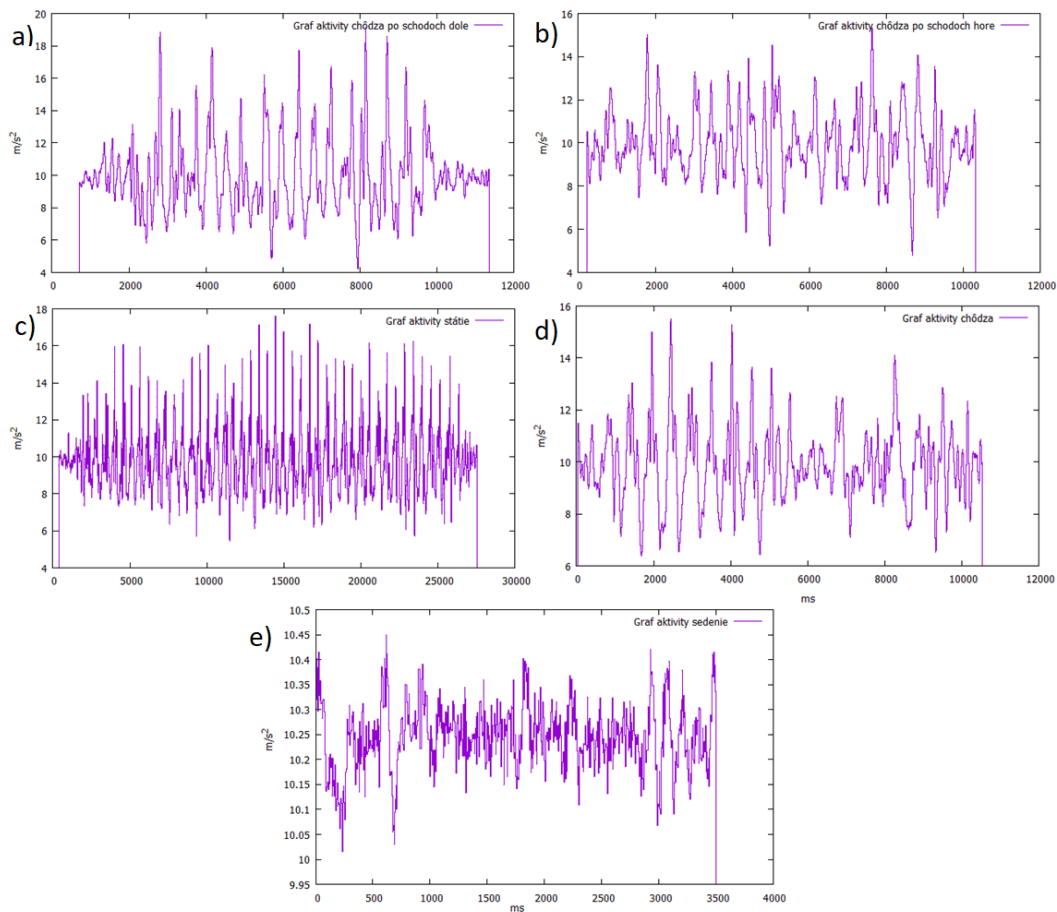
$$a_i = \sqrt{x_i^2 + y_i^2 + z_i^2}$$

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

Medzi jednotlivými grafmi si môžeme všimnúť rozdiely ako napríklad v grafe aktivity sedenie (Obr. 12.e) sa oproti ostatným aktivitám hodnota zrýchlenia na osi y pohybuje len v rozmedzí od 10.00 do 10.45 (tento interval sa môže na iných zariadeniach líšiť), zatiaľ čo pri ostatných aktivitách je rozmedzie mnohonásobne väčšie. Ďalším na pohľad viditeľným rozdielom je to, že pri grafoch cesty výtahom nahor a nadol je vidieť počiatočné a koncové výkyvy zrýchlenia pri rozbíhaní a zastavovaní výtahu, ktoré sú zrkadlovo obrátené (viď. Obr. 11).



Obr. 11: Ukážky nameraných hodnôt akcelerometra pre cestu výtahom dole a hore




Obr. 12: Ukážky nameraných hodnôt akcelerometra pre jednotlivé aktivity (a) chôdza po schodoch dole, b) chôdza po schodoch hore, c) státie, d) chôdza, e) sedenie)

Cieľom je rozpoznať aktivitu používateľa smartfónu na základe nameraných hodnôt v rozsahu maximálne pár sekúnd. Z týchto hodnôt z akcelerometra a gyroskopu sú následne vypočítané zväčša štatistické vlastnosti, ktoré sú vstupom pre algoritmus rozpoznávania, teda neurónovú sieť.

6.1.3 Spracovanie vstupných dát

Vstupom do neurónovej siete môže byť napríklad súbor vybraných vlastností dát zo senzorov. Neurónovú sieť však nie je možné trénovať po každom jednom meraní zo senzora. Pri spracovaní vstupných dát sme sa preto rozhodli dáta rozdeliť na izolované okná jednotnej dĺžky, ktorú si môžeme sami nastaviť ako jeden z parametrov. Navyše sa tieto okná navzájom čiastočne prekrývajú tak, ako je to ilustračne znázornené na Obr. 13.



Obr. 13: 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, ktoré sa využívali aj v iných podobných prácach [1, 2] :

- priemer
- štandardná odchýlka
- variancia
- priemerná absolútna odchýlka
- kvadratický priemer
- medzikvartilový rozsah
- energia (vypočítaná na základe Fourierovej transformácie)
- korelácia medzi osami


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


Týchto 8 vlastností sme vypočítali pre každú z troch osí akcelerometra, čo nám dokopy dáva 24 atribútov pre každé okno. Následne sme si podľa [15] spomedzi troch osí gyroskopu vybrali tú najsenzitívnejšiu, t.j. takú, ktorej údaje dosahujú maximálnu magnitúdu. Tento postup je vhodný preto, že merania gyroskopu vyvolávajú neustále skreslenie dát, termomechanický biely šum, chyby kalibrácie a iné, ktoré sú pri meraní malých hodnôt dosť skresľujúce, ale pri vysokých hodnotách sú zanedbateľné. Najsenzitívnejšiu os gyroskopu vyberieme podľa vzťahu

$$\text{Najsenzitívnejšia os} = \max_{a=x,y,z} \sum_{i=1}^n |\omega_a(i)|,$$

kde $\omega_a(i)$ označuje uhlovú rýchlosť osi $a = x, y, z$ v čase i v rámci aktuálneho časového okna a n je veľkosť časového okna. Následne aj pre túto os vypočítame prvých 7 vlastností (okrem korelácie, keďže máme len jednu os gyroskopu). Spolu máme teda 31 hodnôt atribútov pre každé okno. Všetky dostupné namerané dáta sme takto spracovali a získali sme výsledný dataset, ktorý sme ďalej použili ako vstup pre neurónovú sieť.

Jednotlivé vlastnosti dokážu odlišiť vybrané aktivity s rozdielnou úspešnosťou. Napríklad podľa [16] dokáže priemer spomedzi ostatných spomenutých vlastností odlišiť aktivity s najvyššou presnosťou a to pri použití viacerých metód vrátane viacvrstvovej perceptrónovej siete. Na Obr. 14 sú na ukážku zobrazené histogramy pre vlastnosti priemer pre každú z aktivít, ktoré ukazujú v akom počte (os y) sa vyskytujú jednotlivé hodnoty (os x) priemeru v našom datasete. Niektoré aktivity ako napríklad státie (Obr. 14 a) a chôdzu (Obr. 14 b)) vieme na základe tejto vlastnosti jednoznačne odlišiť, zatiaľ čo aktivity chôdza a chôdza po schodoch oboma smermi (Obr. 14 b, c) a d)) sú si navzájom dosť podobné, čo teda bude mať za následok nižšiu úspešnosť pri ich rozpoznávaní.





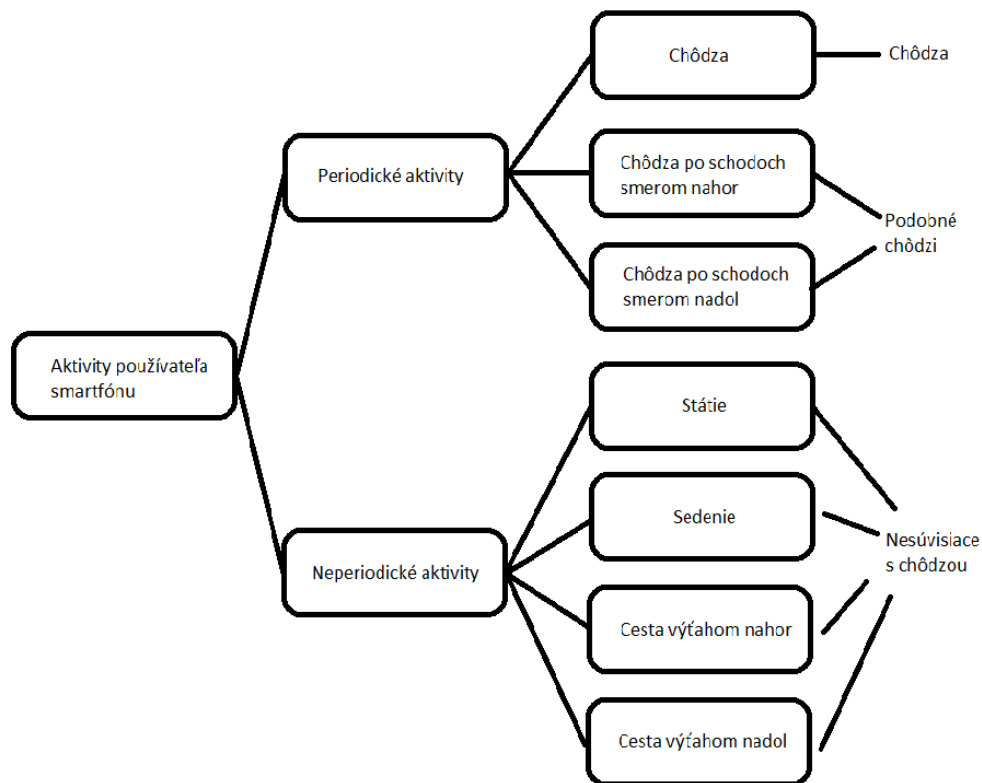
Obr. 14: Histogramy vlastnosti priemer pre aktivity a) státie, b) chôdza, c) chôdza po schodoch smerom nahor, d) chôdza po schodoch smerom nadol, e) sedenie, f) cesta výt'ahom smerom nahor a g) cesta výt'ahom smerom nadol

6.1.4 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 (napr. [2]), s nastaveniami, ktoré sme experimentálne testovali.

Jednou z najdôležitejších premenných bol počet skrytých vrstiev a počet neurónov v nich. Naš model obsahuje vstupnú vrstvu s 31 vstupnými neurónmi, z ktorých každý reprezentuje jeden z atribútov v jednom zázname nášho datasetu, jednu skrytú vrstvu (podobne ako v [2]) s 30 neurónmi a výstupnú vrstvu s 3 neurónmi, ktoré reprezentujú jednotlivé skupiny klasifikácie, konkrétne aktivitu chôdze, aktivitu podobnú chôdzi a aktivitu nesúvisiacu s chôdzou ako je zobrazené na Obr.15., 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. Dĺžku okna sme si takisto experimentálnym postupom na 3 sekundy a prekryvanie okien sme nastavili na 50%. Ostatné premenné ako napríklad učiaci pomer, maximálna veľkosť chybovej funkcie alebo maximálny počet iterácií pri tréningu siete sme si experimentálne nastavovali podľa potreby.



Obr. 15: Klasifikácia aktivít do skupín

6.1.5 Dosiahnuté výsledky

Pri testovaní viacvrstvovej perceptrónovej neurónovej siete sme experimentovali s hodnotami učiaceho pomeru, maximálnou hodnotou chybovej funkcie a maximálnym počtom iterácií a dosiahli sme priemernú úspešnosť nad 98%. V tabuľke 1 sú uvedené výsledky konkrétneho testovania, kde sme mali nastavenú hodnotu učiaceho pomeru 0.03 a testovali sme našu sieť po dobu 1500 iterácií. Hodnota chybovej funkcie na konci tréningu v tomto prípade bola 0.013% a dosiahli sme celkovú úspešnosť 97.99%. Jednotlivé riadky tabuľky reprezentujú dané klasifikačné skupiny aktivít, ktoré boli testované a jednotlivé stĺpce označujú počty odhadnutých aktivít pre každú skupinu aktivít z výstupu siete.

Tabuľka 1. ukazuje takmer 100% úspešnosť pri rozpoznávaní aktivít nesúvisiacich s chôdzou. Pri rozpoznávaní chôdze a aktivít podobných chôdzi bolo o čosi viac chybných výsledkov ale stále sme dosahovali hodnotu úspešnosti nad 95%, pričom chybné výsledky aktivity chôdze boli skoro všetky odhadnuté ako aktivita príbuzná chôdzi a to isté platí aj naopak pre chybné výsledky aktivít podobných chôdzi.

Tab. 1: Tabuľka matice zámen (confusion matrix) viacvrstvovej perceptrónovej siete

	Chôdza	Podobné Chôdzi	Nesúvisiace s chôdzou	Úspešnosť
Chôdza	3434	172	2	95.1774% (3434/3608)
Podobné Chôdzi	154	5699	0	97.3689% (5699/5853)
Nesúvisiace s chôdzou	0	5	7128	99.9299% (7128/7133)

Jedným z riešení tohto problému by mohla byť napríklad integrácia dát z ďalšieho senzora, konkrétne barometra, ktorý by nám poskytol potrebnú informáciu o zmene výšky pri pohybe. V našej práci sme sa ale špecificky zamerali len na rozpoznávanie aktivít z dát z akcelerometra a gyroskopu, vzhľadom na dáta, ktoré boli dostupné z vybraného datasetu a teda takéto vylepšenie sme pre túto metódu neimplementovali.

6.2 Detekcia krokov a odhad dĺžky kroku

Ďalšou metódou na zlepšenie presnosti indoor lokalizácie, ktorú sme sa rozhodli implementovať je detekcia krokov spolu s dodatočnou bonusovou informáciou, konkrétne odhad dĺžky kroku. Na tento účel sme použili model hlbokoj konvolučnej neurónovej siete, podobne ako v Hannik et al.[18].

6.2.1 Dataset eGaIT

Pre tento model sme sa rozhodli použiť dataset eGaIT – embedded Gait analysis using Intelligent Technologies⁴, konkrétne databázu Gait Parameters, ktorá obsahuje dáta od 101 geriatrických pacientov s rôznymi poruchami chôdze. Medzi nimi bolo 55 žien a 46 mužov, s priemerným vekom 82,1 rokov \pm 6,5 rokov a priemernou výškou 164.0 cm \pm 10.0 cm.

Na zber údajov bola použitá platforma senzorov Shimmer2R. Táto jednotka obsahuje 3-osový akcelerometer (rozsah \pm 6 g) a 3-osový gyroskop (rozsah \pm 500° / s) a bola umiestnená laterálne na bočnej strane topánky priamo pod každým členkom (viď. obr. 16). Rovnaký model obuvi (adidas Duramo 3) bol používaný všetkými subjektmi, aby sa zabránilo zmenám v chôdzi kvôli rôznym charakteristiky obuvi. Dáta boli zaznamenané pri snímacej frekvencii 102,4 Hz a rozlíšení 12 bitov. Zároveň boli zaznamenávané aj údaje na validáciu získané pomocou zavedenej tlakovej podložky GAITRite. Citlivá oblasť tlakovej podložky bola 609,60 cm \times 60,96 cm s priestorovým

⁴ Zdroj: <https://www5.cs.fau.de/activitynet/benchmark-datasets/digital-biobank/>

rozlíšením $\pm 1,27$ cm a šírkou trasy 84 cm. Vykonaným cvičením bola chôdza 10 metrov, ktorá sa opakuje 4 krát. Obrovskou výhodou tohto datasetu je, že obsahuje už segmentované dáta jednotlivých krokov.



Obr. 16: Umiestnenie snímačej jednotky a definícia osí.

6.2.2 Predspracovanie dát


Pred vložením dát zo senzorov do modelu našej konvolučnej neurónovej siete je potrebné vykonať sériu krokov predspracovania dát.

Patrí sem extrakcia anotovaných krokov (segmentácia spojitého signálu na kroky je už obsiahnutá v datasete) a následná kalibrácia zo surových dát do fyzických jednotiek pomocou poskytnutých kalibračných súborov, ktoré sú súčasťou datasetu a sú rôzne pre dáta z pravej a ľavej nohy.

Kvôli odlišnému umiestneniu snímačej jednotky na topánkach sú potrebné transformácie súradníc na zosúladenie osí senzorov na ľavej a pravej nohe.

Ďalej prebieha normalizácia dát signálov zo senzorov akcelerometra a gyroskopu s ohľadom na príslušné rozsahy senzorov a potom je použitý tzv. Zero-padding alebo inak povedané doplnenie hodnôt nulami na zabezpečenie rozsahu dĺžky 256 vzoriek na jeden krok, aby sa zabezpečila fixná veľkosť vstupu do siete.

Na všetky spomenuté kroky sme si potrebovali v rámci potrieb nášho modelu značne upraviť a rozšíriť skripty v jazyku Octave, ktoré boli na ukážku poskytnuté v datasete. Na obr.17 môžeme vidieť ukážku predspracovaných dát jedného segmentovaného kroku.




Obr. 17: Ukážka vstupného signálu po predspracovaní.

6.2.3 Štruktúra modelu hlbokoj konvolučnej neurónovej siete

Architektúra neurónovej siete, ktorú sme si vybrali, je dvojvrstvová konvolučná sieť nasledovaná jednou úplne prepojenou vrstvou neurónov. Podrobnú schému modelu siete môžeme vidieť na obr. 19.

Na vstupe máme tzv. „multichannelled synchronized time series data“, t.j. konkrétne 6 súvislých časovo zosynchronizovaných signálov naraz (3 signály z akcelerometra a ďalšie 3 signály z gyroskopu pre každú z osí).

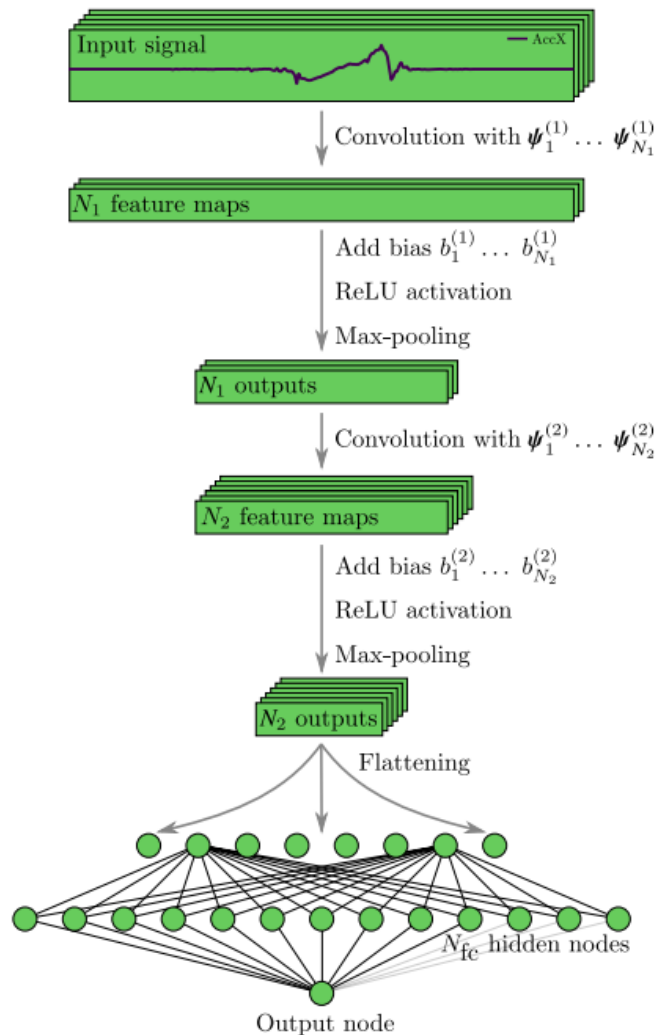
Na prvej vrstve sa skonštruuje N_1 aktivačných máp (feature maps) pomocou N_1 kernelov (filtrov). Ku vzniknutým aktivačným mapám pridáme bias a aplikujeme ReLU aktivačnú funkciu. Následne aplikujeme Max-pooling vrstvu, ktorá slúži na priestorové zmenšenie vstupov z predchádzajúcich vrstiev za účelom zníženia počtu parametrov v nasledujúcich vrstvách a vďaka tomu sa zrýchli tréning takejto siete. Pooling vrstva je reprezentovaná použitým filtrom. Filter na maximum (MAX) vyberá maximálnu hodnotu z oblastí vid'. obr.18. Tak získame N_1 výstupov prvej vrstvy.



Obr. 18: Ukážka MAX pooling

To isté potom znova zopakujeme aj pre druhú konvolučnú vrstvu. Výstupy N_2 „sploštíme“ do jedného vektora a potom nasleduje plne prepojená skrytá vrstva N_{fc} neurónov, kde sme si zatiaľ určili 1024 neurónov v skrytej vrstve.


Na konci máme jeden výstupný neurón, ktorého výstupom bude odhadovaná dĺžka kroku. Teoreticky môžeme použiť viac neurónov na výstupnej vrstve (y_1, \dots, y_n) ak budeme skúmať viac charakteristík kroku (nielen jeho dĺžku). Čo sa týka ostatných parametrov siete chystáme sa generovať hodnoty kernelov náhodne, použijeme optimalizér Adam a taktiež ak to bude potrebné použijeme „dropout“ techniku aby sme zabránili preučeniu siete.



Obr.19: Architektúra modelu konvolučnej siete

6.2.4 Evaluácia modelu siete

Vyhodnotenie navrhovaného modelu plánujeme urobiť pomocou 10-násobnej krížovej validácie (10-fold cross validation) ako je znázornené na obr. 20. Kroky od 101 subjektov v datasete sú rozdelené do tréningovej a testovacej množiny v závislosti od poskytnutého identifikátora subjektov aby sa zaistilo odlišné/zreteľné rozdelenie datasetu.



Obr. 20: Schéma 10-násobnej krížovej validácie.

7 Ďalší postup

Ďalším krokom v tejto práci bude vyhodnotenie výsledkov modelu hlbokoj konvolučnej neurónovej siete a takisto experimentovanie s parametrami tohto modelu za účelom dosiahnutia čo najlepších výsledkov. Ďalej sa plánujeme venovať návrhu, implementácii a prezentácii výsledkov ďalších samostatných alebo čiastkových metód. Ďalej sa v rámci práce môžeme zamerať na napríklad:

- Otestovanie viacerých získaných datasetov a porovnanie získaných výsledkov z rôznych datasetov na našich modeloch.
- Rozšírenie modelu konvolučnej siete na odhad niektorých ďalších bonusových informácií pri detekcii kroku, ktoré vybraný dataset obsahuje, konkrétne prichádzajú do úvahy parametre čas kroku, čas švihy kroku alebo čas státia.
- Implementovanie LSTM modelu neurónovej siete, ktorá je v tejto oblasti veľmi populárna.

V rámci každého spomenutého príkladu potom implementovať a overiť ich použiteľnosť a presnosť.

Ďalší dataset prichádzajúci do úvahy je SLEDataset [14], ktorý slúži na vyhodnocovanie výkonu modelov na odhad dĺžky krokov s využitím senzorov. Dataset obsahuje viac ako 22 kilometrov záznamov v JSON formáte získaných od 15 zdravých dospelých pre 3 rôzne rýchlosti chôdze a 4 rôzne pozície senzoru typické pre užívateľov smartfónov.

Pod'akovanie

Týmto sa chcem poďakovať konzultantovi mojej diplomovej práce RNDr. Miroslavovi Opielovi a vedúcemu práce RNDr. Ľubomírovi Antonimu, PhD. za pomoc s výberom témy diplomovej 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.
- [4]. Davidson, P., & Piche, R. (2017). A Survey of Selected Indoor Positioning Methods for Smartphones. IEEE Communications Surveys and Tutorials, 19(2), 1347-1370. <https://doi.org/10.1109/COMST.2016.2637663>
- [5]. Activity Recognition API (zdroj: <https://developers.google.com/location-context/activity-recognition>)
- [6]. MENDOZA-SILVA, G. M. et al.. A Meta-Review of Indoor Positioning Systems. In Sensors. ISSN 1424-8220, 2019, vol. 19, no. 20, p. 4507..
- [7]. RADU, V. et al.. Multimodal Deep Learning for Activity and Context Recognition. In Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies. ISSN 2474-9567, 2017, vol. 1, no. 4, p. 1-27.
- [8]. WANG, X. et al.. DeepML: Deep LSTM for Indoor Localization with Smartphone Magnetic and Light Sensors. In 2018 IEEE International Conference on Communications (ICC). Kansas City, MO, USA: IEEE, 2018. ISBN 978-1-5386-3180-5, p. 1-6.
- [9]. Wang, L., Liu, R. Human Activity Recognition Based on Wearable Sensor Using Hierarchical Deep LSTM Networks. *Circuits Syst Signal Process* 39, 837–856 (2020).
- [10]. Congcong Ma, Wenfeng Li, Jingjing Cao, Juan Du, Qimeng Li, Raffaele Gravina, Adaptive sliding window based activity recognition for assisted livings, Information Fusion, Volume 53, 2020, Pages 55-65, ISSN 1566-2535.
- [11]. Maghdid, H.S.; Lami, I.A.; Ghafoor, K.Z.; Lloret, J. Seamless Outdoors-Indoors Localization Solutions on Smartphones. *ACM Comput. Surv.* 2016, 48, 1–34
- [12]. UCI Machine Learning Repository (zdroj: <http://archive.ics.uci.edu/ml/datasets/heterogeneity+activity+recognition>)
- [13]. Vezocnik, Juric - 2018 - Average Step Length Estimation Models' Evaluation Using Inertial Sensors A Review

- [14]. SLEDataset (zdroj:
<https://github.com/repositoryadmin/SLERepository/tree/master/SLEDataset>)
- [15]. Qi, Guodong & Huang, Baoqi. (2018). Walking Detection Using the Gyroscope of an Unconstrained Smartphone. 539-548. 10.1007/978-3-319-66628-0_51.
- [16]. AWAN, Muhammad Arshad, et al. Subject-independent human activity recognition using Smartphone accelerometer with cloud support. *International Journal of Ad Hoc and Ubiquitous Computing*, 2015, 20.3: 172-185.
- [17]. Ao B, Wang Y, Liu H, Li D, Song L, Li J. Context Impacts in Accelerometer-Based Walk Detection and Step Counting. *Sensors (Basel)*. 2018;18(11):3604. Published 2018 Oct 24. doi:10.3390/s18113604
- [18]. J. Hannink et al., "Mobile Stride Length Estimation With Deep Convolutional Neural Networks," in *IEEE Journal of Biomedical and Health Informatics*, vol. 22, no. 2, pp. 354-362, March 2018, doi: 10.1109/JBHI.2017.2679486.
- [19]. A. Rampp, J. Barth, S. Schülein, K.-G. Gaßmann, J. Klucken et al., "Inertial Sensor Based Stride Parameter Calculation from Gait Sequences in Geriatric Patients." *IEEE Transactions on Biomedical Engineering*, vol. 62, no. 4, pp. 1089–1097, 2014