

Indoor lokalizácia používateľa smartfónu s využitím neurónových sietí

Diplomová práca

Detaily:

- **Názov diplomovej práce:**

Indoor lokalizácia používateľa smartfónu s využitím neurónových sietí

- **Fakulta / Univerzita: Prírodovedecká fakulta UPJŠ v Košiciach**

- **Stredisko: ÚINF - Ústav informatiky**

- **Akademický rok: 2020/2021**

- **Vedúci: RNDr. Ľubomír Antoni PhD.**

- **Konzultant: RNDr. Miroslav Opiela**

- **Autor: Patrik Rojek**


Ciele:

- 1) Preskúmať využitie neurónových sietí na rozpoznávanie aktivity používateľa smartfónu.**
- 2) Navrhnuť samostatné alebo čiastkové metódy založené na strojovom učení využívajúce senzory smartfónu alebo iného zariadenia s cieľom zlepšiť presnosť indoor lokalizácie.**
- 3) Implementovať a overiť použiteľnosť a presnosť navrhnutých prístupov.**

Indoor lokalizácia – Indoor positioning system (IPS)

Čo je IPS ?

- sieť zariadení, ktoré sa využívajú na lokalizáciu objektov alebo ľudí vo vnútri budov
- na rozdiel od využitia satelitných technológií, IPS sa spolieha na blízke kotviace uzly (body so známou pozíciou), ktoré buď aktívne podieľajú na lokalizácii alebo poskytujú kontext okolitého prostredia



Activity recognition


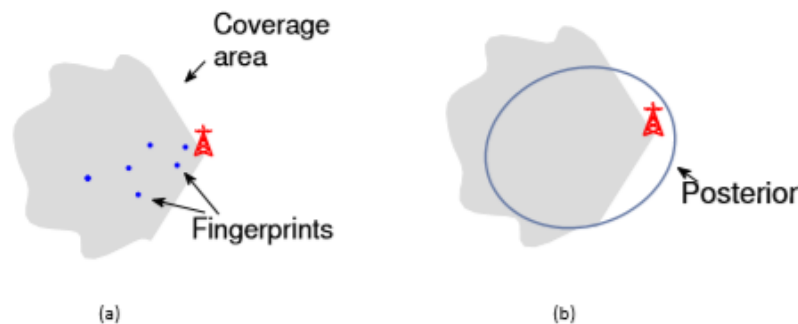

- rozpoznávanie aktivity daného užívateľa na základe získaných dát (senzory) a okolitých podmienok
- rôzne aplikácie v oblastiach medicíny, navigácie, sociológie a iné
- môže byť vyhodnocované rôznymi metódami (neurónové siete, data mining a iné)



Existujúce metódy určovania polohy v indoor prostredí s využitím smartfónu

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

- **Rádio mapy,**
- **Deterministické algoritmy** - k-nearest neighbour (KNN), weighted k-nearest neighbour (WKNN),
- **Pravdepodobnostné algoritmy** - modely coverage area a path-loss,
- **Metódy strojového učenia** - state vector machines (SVM), vážené rozhodovacie stromy, a deep learning (napr. HLSTM siete (4))



Existujúce metódy určovania polohy v indoor prostredí s využitím smartfónu

Určovanie polohy pomocou magnetických polí

- mapa distribúcie magnetického poľa vo vnútri budov
- pozostáva z dvoch fáz:
 - offline mapovanie meraní magnetického poľa na známych miestach
 - online určovanie polohy porovnaním meraného magnetického poľa s odtlačkami signálov z databázy
- **výhody:**
 - magnetické pole je všade, je relatívne stabilné, a preto nie je potrebná žiadna predinštalovaná infraštruktúra
- **nevýhody:**
 - gradient magnetického poľa môže byť niekedy veľmi strmý
 - môžu sa vyskytnúť magnetické interferencie
 - pozícia smartfónu sa môže voľne meniť
 - ďalšími výzvami použitia magnetického poľa na určovanie polohy pomocou smartfónov sú rozmanitosť zariadení a scenáre použitia a výrazná variabilita magnetického poľa s nadmorskou výškou (na rovnakej ceste)

Existujúce metódy určovania polohy v indoor prostredí s využitím smartfónu

Prístupy s využitím mapy v indoor prostredia

Existujú tri prístupy, ktoré je možné implementovať do smartfónov:

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

Účelom týchto algoritmov je zlepšiť lokalizáciu úpravou odhadovanej cesty vzhľadom k plánu budovy.

Existujúce metódy určovania polohy v indoor prostredí s využitím smartfónu

Použitie senzorov smartfónov na lokalizáciu


Je potreba vyrovnať so zmenou orientácie telefónu bez akýchkoľvek obmedzení týkajúcich sa scenárov použitia.

A. Detekcia chôdze a počítanie krokov

B. Odhad dĺžky kroku

- jednoduché algoritmy počítajú iba kroky za predpokladu, že dĺžka kroku je iba priemerom pre daného používateľa.
- pokročilé algoritmy tiež vykonávajú presnú segmentáciu krokov a analyzujú signály akcelerometra, aby individuálne odhadli veľkosť každého kroku.
- väčšina z týchto systémov však vyžaduje kalibráciu na individuálneho používateľa, pretože chôdza každého používateľa je rôzna.

C. Odhad smeru chôdze (Walking direction estimation)



Major tasks that can be performed using smartphone sensors.

Activity Recognition API by Google

- automaticky zisťuje aktivitu 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 nízkej spotreby na obnovenie podávania správ, keď zistí pohyb
- dajú sa detekovať nasledujúce aktivity (z ktorých každá zahŕňa aj úroveň pravdepodobnosti): IN_VEHICLE, ON_BICYCLE, ON_FOOT, RUNNING, WALKING, STILL, TILTING, UNKNOWN



- **Minimálne požiadavky:**
 - 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

Ďalší postup

- Vytvorenie a vyskúšanie modelu na detekciu krokov so zameraním sa na nejakú bonusovú informáciu - dĺžkou kroku alebo natočením, rýchlosťou, a pod.
- Výber ďalších metód s cieľom zlepšiť presnosť indoor lokalizácie:
 - Integrácia dát z viacerých senzorov - okrem akcelerometra napr. barometer, magnetometer, svetelný senzor
 - Rozpoznávanie viacerých aktivít alebo viacerých pozícií zariadenia.
 - Využitie rôznych zariadení- okrem telefónu napr. smart okuliare, náramky, hodinky a pod.
 - Rozpoznávanie „kľúčových“ miest v rámci budovy, kde je lokalizácia náročnejšia
- Implementovať a overiť použiteľnosť a presnosť navrhnutých prístupov/metód

Literatúra:

- 1) 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..
- 2) 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.
- 3) 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.
- 4) Wang, L., Liu, R. Human Activity Recognition Based on Wearable Sensor Using Hierarchical Deep LSTM Networks. *Circuits Syst Signal Process* 39, 837–856 (2020).

Literatúra:

- 5) 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.
- 6) Davidson, P., & Piche, R. (2017). A Survey of Selected Indoor Positioning Methods for Smartphones. IEEE Communications Surveys and Tutorials, 19(2), 1347-1370.
- 7) 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

Ďakujem za pozornosť.