

# **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

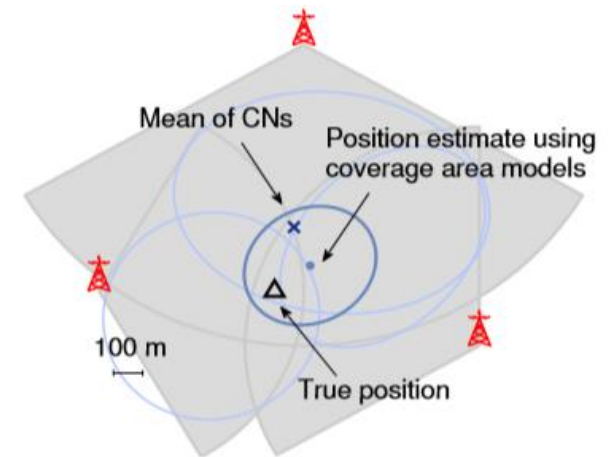
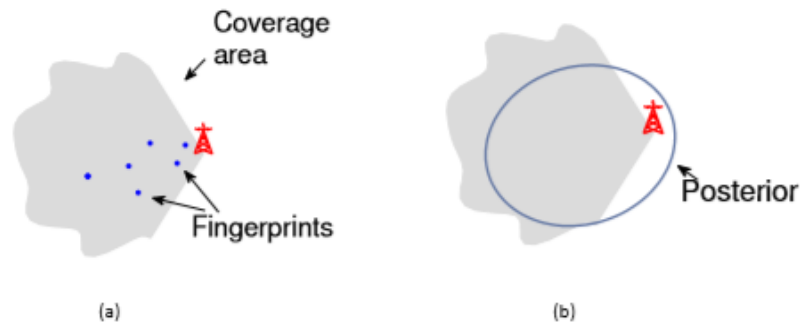

- rozpoznávanie aktivity daného užívateľa na základe získaných dát (senzory) a okolitých podmienok
- rôzne aplikácie v oblastiach medicíny, navigácie, sociológie a iné
- môže byť vyhodnocované rôznymi metódami (neurónové siete, data mining a iné)



# 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 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

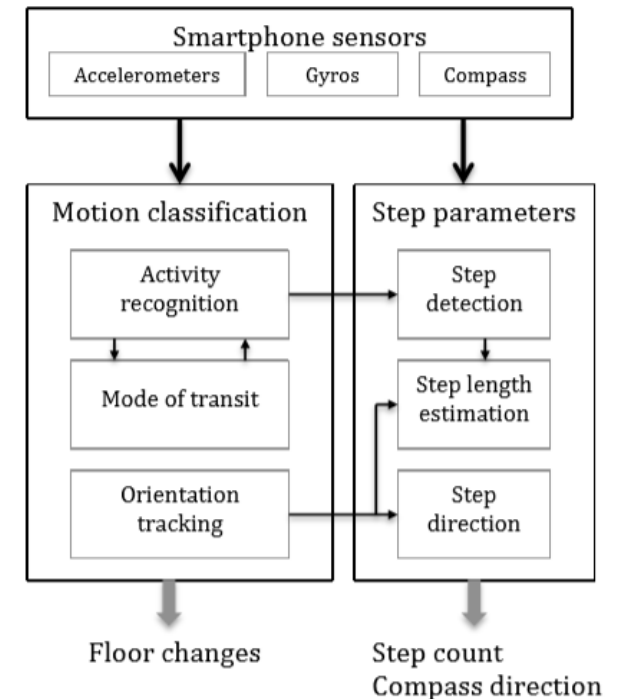
Je potreba vyrovnať so zmenou orientácie telefónu bez akýchkoľvek obmedzení týkajúcich sa scenárov použitia.

### 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.

# Datesety

## Walk detection and step counting on unconstrained smartphones

- surové dáta zo senzorov smartfónu,
- 27 účastníkov,
- 3 rýchlosti chôdze na rovnakej trase,
- rôzne umiestnenia smartfónu
- frekvencia 100Hz
- dáta uložené binárne



## Human Activity Recognition Using Smartphones

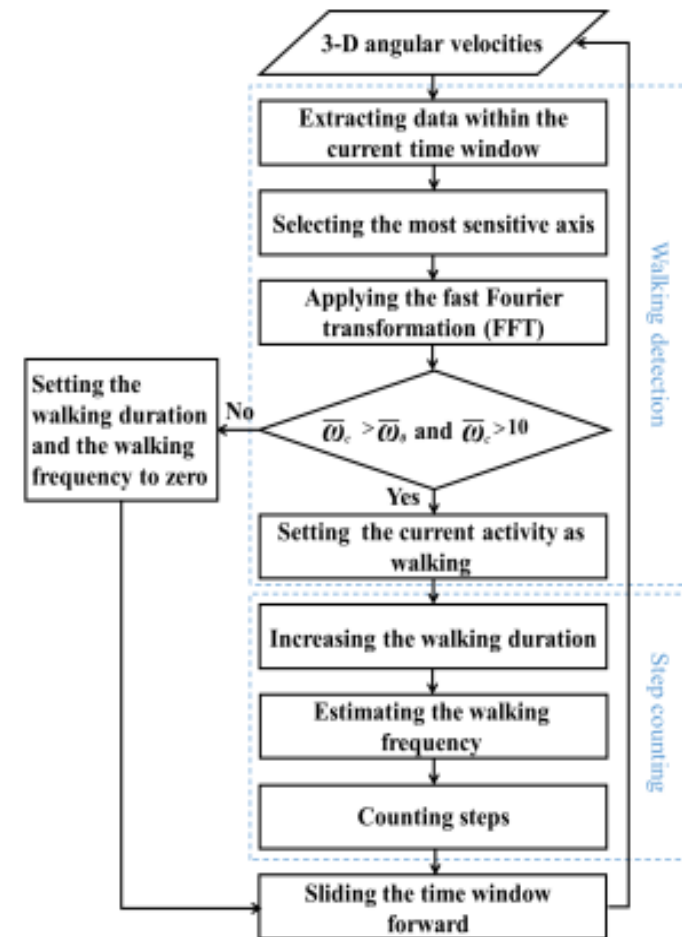
- dáta predspracované pomocou noise filtrov a rozdelené do 2.56s posuvných okien s prekryvom 50%,
- 30 účastníkov,
- 6 rôznych aktivít
- frekvencia 50Hz
- každý záznam obsahuje vektor 561 vlastností

# Walk detection, step count and length estimation

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 (50-200Hz)

Spomedzi metód strojového učenia sa využívajú napríklad k-NN (k-najbližších susedov) alebo SVM (Support Vector Machine), ktoré dosahujú dobré výsledky.

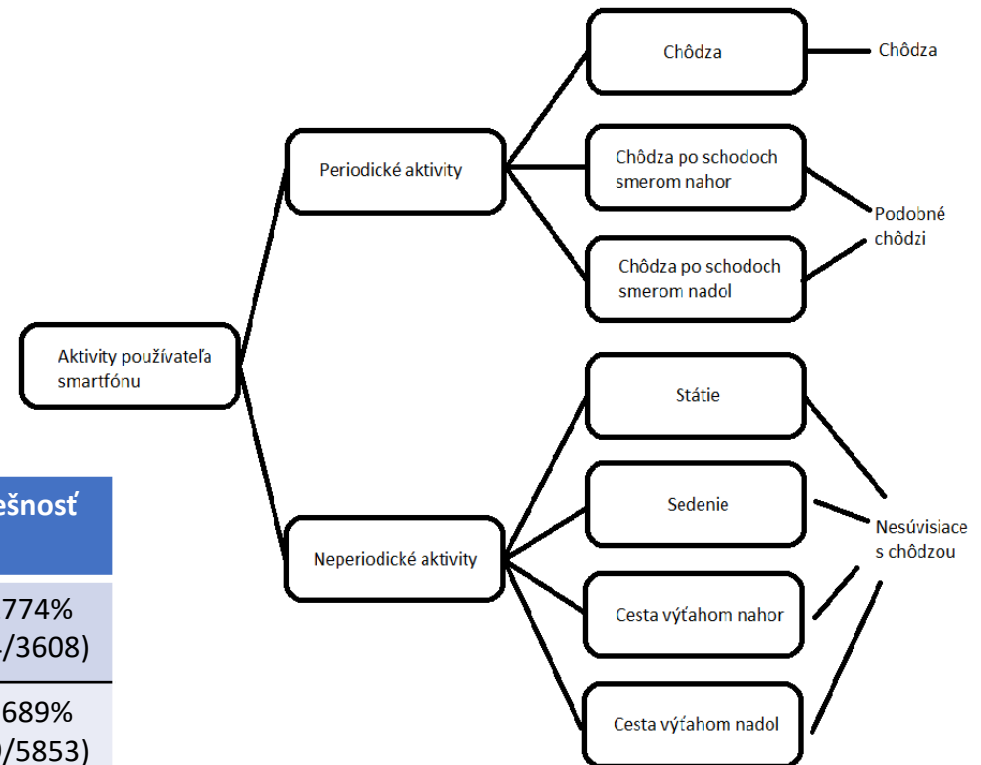


# Prvý experiment

## Viacvrstvová perceptrónová neurónova sieť

- Detekcia aktivity chôdze od aktivít, ktoré sú podobné chôdzi (chôdza po schodoch hore/dole) a od aktivít, ktoré nesúvisia s chôdzou (státie, sedenie, cesta výťahom)
- Dosiahnutá presnosť 98%
- Confusion matrix:

	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)



# Step detection and Length estimation

## Databáza eGait – embedded Gait analysis using Intelligent Technologies

### 1. Validácia segmentácie kroku

- pozostáva z údajov od 70 subjektov, prevažne starších osôb a osôb s pohybovými poruchami, napr. Parkinsonovou chorobou

### 2. Validácia parametrov chôdze

- pozostáva z údajov od 101 osôb (55 žien a 46 mužov, vek  $82,1 \pm 6,5$  rokov), ktorí vykonali testy priamej chôdze.
- zber dát pomocou jednotky obsahujúcej 3-osový akcelerometer a 3-osový gyroskop umiestnenej na bočnej strane topánky
- snímacia frekvencia 102.4Hz



Umiestnenie jednotky a definícia osí.

# Preprocessing dát


Pred vložením dát zo senzorov do modelu neurónovej siete je potrebné vykonať nasledujúce kroky:

1. Extrakcia anotovaných krokov (segmentácia spojitého signálu na kroky je už obsiahnutá v datasete)
2. Kalibrácia zo surových dát do fyzických jednotiek
3. Transformácie súradníc na zosúladenie osí senzorov na ľavej a pravej nohe
4. Normalizácia dát signálov zo senzorov akcelerometra a gyroskopu
5. Zero-padding na zabezpečenie rozsahu dĺžky 256 vzoriek na jeden krok, aby sa zabezpečila fixná veľkosť vstupu do siete.

# Architektúra modelu siete


## Dvojvrstvová konvolučná neurónová sieť nasledovaná jednou plne prepojenou vrstvou neurónov

- Na vstupe máme „multichannelled synchronized time series“, t.j. 6 súvislých signálov naraz (3+3), ktoré sú zosynchronizované do rovnakého času.
- Na prvej vrstve sa skonštruuje  $N_1$  aktivačných máp (feature maps) pomocou  $N_1$  kernelov (filtrov).
- Ku vzniknutým aktivačným mapám pridáme bias
- Aplikujeme ReLU aktivačnú funkciu
- Aplikujeme Max-pooling
- Získame  $N_1$  výstupov prvej vrstvy



# Architektúra modelu siete

- To isté potom znova zopakujeme aj pre druhú konvolučnú vrstvu
- Výstupy  $N_2$  „sploštíme“ do jedného vektora
- Nasleduje plne prepojená skrytá vrstva  $N_{fc}$  neurónov
- 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)

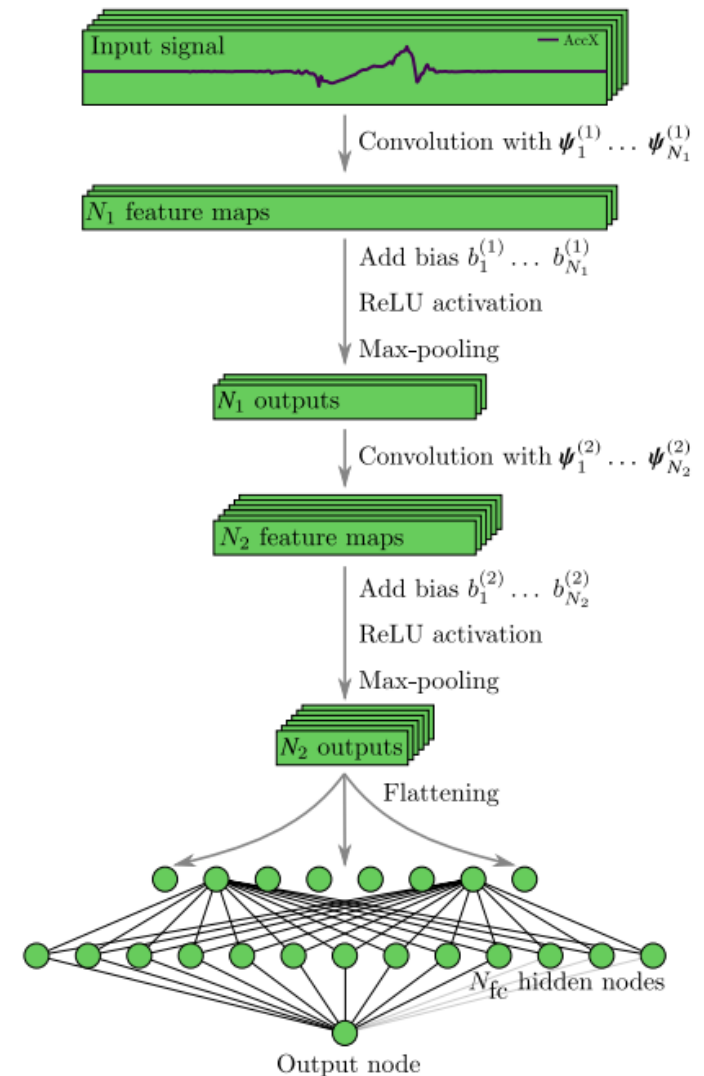




# Architektúra modelu siete


Modifikovateľné premenné modelu:

- počet a veľkosti konvolučných filtrov
- bias
- aktivačná funkcia
- veľkosť okien pri Max-poolingu
- počet neurónov v skrytej vrstve
- výber iného optimalizéra na nastavenie váh
- nastavenie Dropout-u



# Evaluácia modelu siete

- vyhodnotenie modelu pomocou 10-násobnej krížovej validácie (10-fold cross validation)
- 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



# 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**
- **8) Context Impacts in Accelerometer-Based Walk Detection and Step Counting; Buke Ao, Yongcai Wang, Hongnan Liu, Deying Li, Lei Song and Jianqiang Li; 2018**
- **9) A Novel Walking Detection and Step Counting Algorithm Using Unconstrained Smartphones Xiaomin Kang, Baoqi Huang and Guodong Qi, 2018**

# Literatúra:

- **10) Hannink-et-al.-2017-Mobile-Stride-Length-Estimation-with-Deep-Convolutional-Neural-Networks-1**
- **11) Barth, J., Oberndorfer, C., Pasluosta, C., Schülein, S., Gassner, H., Reinfelder, S., Kugler, P., Schuldhaus, D., Winkler, J., Klucken, J., & Eskofier, B. M. (2015). Stride Segmentation during Free Walk Movements Using Multi-Dimensional Subsequence Dynamic Time Warping on Inertial Sensor Data. *Sensors*, 15(3), 6419-6440.**
- **12) Rampp, A., Barth, J., Schülein, S., Gaßmann, K.-G., Klucken, J., & Eskofier, B. M. (2015). Inertial Sensor-Based Stride Parameter Calculation From Gait Sequences in Geriatric Patients. *IEEE Transactions on Biomedical Engineering*, 62(4), 1089-1097.**

**Ďakujem za pozornosť.**