

Univerzita Palackého v Olomouci
Prírodovedecká fakulta
Katedra geoinformatiky

ANALÝZA A VIZUALIZÁCIA DÁT SLUŽBY
GOOGLE LOCATION

Bakalárska práca

Ľuboš RYBNÍKÁR

Vedúci práce RNDr. Jaroslav BURIAN, PhD.

Olomouc 2019
Geoinformatika a geografia

ANOTÁCIA

Hlavným cieľom bakalárskej práce je otestovať možnosti využitia dát služby Google Location pre časopriestorové analýzy pohybu osôb.

V teoretickej časti práce sú opísané metódy záznamu dát služby Google Location a metódy analýzy dát z GPS prijímačov, sociálnych sietí a dotazníkov pre identifikáciu priestorových vzorcov pohybu osôb.

V praktickej časti sú dáta zozbierané študentom a dáta poskytnuté vedúcim práce a študentami katedry geoinformatiky použité pre analýzu priestorových vzorcov pohybu osôb. Dáta sú najprv prekonvertované do formátu vhodného na ďalšie spracovávanie v štatistických softvéroch a geografických informačných systémoch. Následne sú z dát vybrané tie, ktoré sú použiteľné pre ďalšie analýzy a vizualizácie. Dáta, ktoré boli vybrané sú najprv podrobené štatistickým analýzám, aby sa lepšie spoznala ich štruktúra a potom sú vizualizované vo forme webových aplikácií vyjadrujúcich intenzitu všetkých typov aktivity a časové rozptýlenie celkovej aktivity, analógových máp vyjadrujúcich intenzitu vybraných typov aktivity vo vybraných územiach a digitálnych máp vyjadrujúcich líniové trajektórie pohybu v rámci mesta Olomouc. Výsledky analýz a vizualizácií sú následne interpretované. Interpretáciou dát sú opísané priestorové a časové vzorce pohybu osôb popisujúce ich dopravné správanie.

KLÚČOVÉ SLOVÁ

analýza; typ aktivity; google location; história polohy; vizualizácia

Počet strán práce: 52

Počet príloh: 30 (z toho 5 viazaných, 25 voľných)

ANOTATION

The main goal of the bachelor thesis is to test the possibilities of the usage of Google Location data for the spatiotemporal analysis of the human movement.

In the theoretical part the methods of recording the Google Location data are described together with the methods of the analysis of data from GPS receivers, social networks and questionnaires for the identification of the spatiotemporal patterns of movements of the people.

In the practical part the data collected by the student together with the data given by the mentor and by the students from the department of geoinformatics are being used for the spatiotemporal analysis of the movement of the people. The data are firstly converted to the format suitable for the further work in the statistical software and geographic information systems. Then the data suitable for the further analysis and visualizations are being chosen from the datasets. Afterwards, the data that were chosen undergo firstly the statistical analysis, so we can get to know their structure better and then they are visualized in the form of web applications showing the intensity of the all types of activity and the temporal distribution of the overall activity, paper maps showing the intensity of the specific types of activity at the specific regions and digital maps showing the line trajectories of movement in the city of Olomouc. The results of the analysis and visualizations are then being interpreted. By their interpretation the spatial and temporal patterns of the movement of the people describing their traffic behavior are described.

KEYWORDS

analysis; activity type; google location; location history; visualisation

Number of pages: 52

Number of appendixes: 30

Čestne prehlasujem, že

- bakalársku prácu vrátane príloh, som vypracoval(a) samostatne a uviedol som všetky použité podklady a literatúru.

- som si vedomý, že na moju bakalársku prácu sa plne vzťahuje zákon č.121/2000 Sb. - autorský zákon, hlavne § 35 – využitie diela v rámci občianskych a náboženských obradov, v rámci školských predstavení a využitie diela školského, a § 60 – školské dielo,

- beriem na vedomie, že Univerzita Palackého v Olomouci (ďalej UP Olomouc) má právo nezárobkovo, k svojej vnútornej potrebe, bakalársku prácu používať (§ 35 odst. 3),

- súhlasím, aby jeden výtlačok bakalárskej práce bol uložený v Knížnici UP k prezenčnému nahliadnutiu,

- súhlasím, že údaje o mojej bakalárskej práci budú zverejnené v Študijnom informačnom systéme UP,

- v prípade záujmu UP Olomouc uzatvorím licenčnú zmluvu s oprávnením použiť výsledky a výstupy mojej bakalárskej práce v rozsahu § 12 odst. 4 autorského zákona,

- použiť výsledky a výstupy mojej bakalárskej práce alebo poskytnúť licenciu k jej využitiu môžem len so súhlasom UP Olomouc, ktorá je oprávnená v takom prípade od mňa požadovať primeraný príspevok na úhradu nákladov, ktoré boli UP Olomouc na vytvorenie diela vynaložené (až do ich skutočnej výšky).

V Olomouci dňa _____

Plné meno autora: *Luboš Rybníkář*
podpis autora:

Ďakujem vedúcemu práce RNDr. Jaroslavovi Burianovi, Ph.D. za neustálu pomoc, cenné rady, návrhy na zlepšenie a pripomienky pri vypracovávaní práce. Ďalej ďakujem Mgr. Tomášovi Pohankovi za pomoc pri spúšťaní skriptu na konverziu dát z Google Location, RNDr. Stanislavovi Popelkovi, Ph.D. za oboznámenie s programom V-Analytics a RNDr. Alene Vondrákovej, Ph.D., LL.M. za pomoc pri výbere stupníc pre heatmapy.

Za poskytnutie dát z Google Location pre účely spracovania v práci ďakujem 15 študentom katedry geoinformatiky.

UNIVERZITA PALACKÉHO V OLMOUCI
Přirodovědecká fakulta
Akademický rok: 2017/2018

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Ľuboř RYBNIKÁR**
Osobní číslo: **R16406**
Studijní program: **B1301 Geografie**
Studijní obor: **Geoinformatika a geografie**
Název tématu: **Analýza a vizualizace dat služby Google Location**
Zadávající katedra: **Katedra geoinformatiky**

Z á s a d y p r o v y p r a c o v á n í :

Hlavním cílem diplomové práce je otestovat možnosti využití dat služby Google Location pro časoprostorové analýzy pohybu osob. Student nejprve nastuduje metody záznamu dat služby Google Location a metody analýzy dat GPS trajektorií pro identifikaci prostorových vzorců pohybu osob. V praktické části práce budou využita individuální data sesbíraná studentem (případně data poskytnutá na základě souhlasu dalších osob). Pomocí těchto dat student zpracuje vybrané analýzy pohybu osob za účelem identifikace individuálních prostorových vzorců popisujících dopravní chování (např. převažující typ dopravního prostředku, nejnavštěvovanější místa nebo nejčastější trasy). Vytvořené analýzy budou dále vizualizovány a interpretovány.

Student vyplní údaje o všech datových sadách, které vytvořil nebo získal v rámci práce, do Metainformačního systému katedry geoinformatiky a současně vytvoří zálohu údajů ve formě validovaného XML souboru. Celá práce (text, přílohy, výstupy, zdrojová a vytvořená data, XML soubor) se odevzdá v digitální podobě na CD (DVD) a text práce s vybranými přílohami bude odevzdán ve dvou svázaných výtiscích na sekretariát katedry. O diplomové práci student vytvoří webovou stránku v souladu s pravidly dostupnými na stránkách katedry. Práce bude zpracována podle zásad dle Voženílek (2002) a závazné šablony pro diplomové práce na KGI.

Rozsah grafických prací: **dle potřeby**
Rozsah pracovní zprávy: **max. 50 stran**
Forma zpracování bakalářské práce: **tištěná**
Seznam odborné literatury: **viz příloha**

Vedoucí bakalářské práce: **RNDr. Jaroslav Burian, Ph.D.**
Katedra geoinformatiky

Datum zadání bakalářské práce: **11. května 2018**
Termín odevzdání bakalářské práce: **13. května 2019**

doc. RNDr. Martin Kubala, Ph.D.
děkan

L.S.

UNIVERZITA PALACKÉHO V OLOMOUCI
PŘÍRODOVĚDECKÁ FAKULTA
KATEDRA GEONFORMATIKY
17. listopadu 40, 771 46 Olomouc

prof. RNDr. Vít Voženilek, CSc.
vedoucí katedry

V Olomouci dne 15. května 2018

Příloha zadání bakalářské práce

Seznam odborné literatury:

Šablona KGI pro psaní bakalářských a magisterských prací

VOŽENÍLEK, V.: Diplomové práce z geoinformatiky, Vydavatelství UP, Olomouc, 2002, 60 s.

Odborné publikace zaměřené na zpracování GPS trajektorií a na analýzy prostorových vzorců, např.:

Frantal, Bohumil. 2012. Prostorové Chování: Vzorce Aktivit, Mobilita a Každodenní Život ve Městě. Masarykova univerzita.

Pojsl, Lukáš. 2014. "KAŽDODENNÍ PROSTOROVÁ MOBILITA OBYVATEL VE MĚSTĚ STRAKONICE: VZORCE INDIVIDUÁLNÍ MOBILITY A JEJICH STUDIUM POMOCÍ MODERNÍCH GEOINFORMAČNÍCH TECHNOLOGIÍ."

LIAO, L., D. J. PATTERSON, D. FOX, and H. KAUTZ. 2006. "Building Personal Maps from GPS Data." *Annals of the New York Academy of Sciences* 1093 (1): 249-65. doi:10.1196/annals.1382.017.

Sohn, Timothy, Alex Varshavsky, Anthony LaMarca, Mike Y. Chen, Tanzeem Choudhury, Ian Smith, Sunny Consolvo, Jeffrey Hightower, William G. Griswold, and Eyal de Lara. 2006. "Mobility Detection Using Everyday GSM Traces." In , 212-24. Springer, Berlin, Heidelberg. doi:10.1007/11853565_13.

Naserian, Elahe, Xinheng Wang, Keshav Dahal, Zhi Wang, and Zaijian Wang. 2018. "Personalized Location Prediction for Group Travellers from Spatial-temporal Trajectories." *Future Generation Computer Systems* 83 (June): 278-92. doi:10.1016/j.future.2018.01.024.

Wang, Zhenzhen, Sylvia Y. He, and Yee Leung. 2018. "Applying Mobile Phone Data to Travel Behaviour Research: A Literature Review." *Travel Behaviour and Society* 11 (April): 141-55. doi:10.1016/j.tbs.2017.02.005.

Salomón, Sergio, Cristina Trnuc, Rafael Duque, and José Luis Monta?a. 2017. "Daily Routines Inference Based on Location History." In , 828-39. doi:10.1007/978-3-319-67585-5_80.

Allahviranloo, Mahdieh, and Will Recker. 2015. "Mining Activity Pattern Trajectories and Allocating Activities in the Network." *Transportation* 42 (4): 561-79. doi:10.1007/s11116-015-9602-5.

Krumm, John, and Eric Horvitz. 2006. "Predestination: Inferring Destinations from Partial Trajectories." In , 243-60. doi:10.1007/11853565_15.

Giannotti, Fosca, Mirco Nanni, Fabio Pinelli, and Dino Pedreschi. 2007. "Trajectory Pattern Mining." In *Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '07*, 330. New York, New York, USA: ACM Press. doi:10.1145/1281192.1281230.

Ye, Yang, Yu Zheng, Yukun Chen, Jianhua Feng, and Xing Xie. 2009. "Mining Individual Life Pattern Based on Location History." In *2009 Tenth International Conference on Mobile Data Management: Systems, Services and Middleware*, 1-10. IEEE. doi:10.1109/MDM.2009.11.

OBSAH

ZOZNAM POUŽITÝCH SKRATIEK.....	10
ÚVOD	11
1 CIELE PRÁCE.....	12
2 METÓDY A POSTUPY SPRACOVANIA.....	13
2.1 Použité metódy	13
2.2 Použité dáta.....	13
2.3 Použité programy	13
2.4 Postup spracovania.....	14
3 SÚČASNÝ STAV RIEŠENEJ PROBLEMATIKY	17
3.1 Analýzy pohybu osôb z dát získaných dotazníkovým šetrením	17
3.2 Analýzy pohybu osôb z dát získaných z GPS prijímačov a sociálnych sietí	18
3.2.1 Študentské práce	18
3.2.2 Práce zahraničných expertov	20
3.3 Google história polohy.....	25
4 VLASTNÉ RIEŠENIE	28
4.1 Stiahnutie a konverzia dát	28
4.2 Vyhodnotenie vzniknutej bodovej vrstvy	31
4.2.1 Odstránenie záznamov s odchýlkou	31
4.2.2 Určenie typu aktivity	32
4.3 Štatistická analýza dát.....	34
4.4 Kartografická vizualizácia dát.....	35
4.4.1 Webové mapové aplikácie	35
4.4.2 Analógové mapy	37
4.4.3 Vizualizácie trajektórií vo V-Analytics	37
5 VÝSLEDKY	39
5.1 Výsledky štatistických analýz a ich interpretácia	39
5.1.1 Presnosť dát služby Google Location	39
5.1.2 Rozptyl hodnôt pravdepodobnosti dát služby Google Location.....	39
5.2 Výsledky kartografických vizualizácií a ich interpretácia	43
5.2.1 Popis výsledkov	43
5.2.2 Interpretácia výsledkov.....	44
6 DISKUSIA.....	50
7 ZÁVER	52
POUŽITÁ LITERATURA A INFORMAČNÉ ZDROJE	
PRÍLOHY	

ZOZNAM POUŽITÝCH SKRATIEK

Skratka	Význam
CSV	Comma Separated Value
ESRI	Environmental System Research Institute
GEOJSON	Geo Java Script Object Notation
GIS	geografický informačný systém
GPS	globálny polohový systém
JSON	Java Script Object Notation
KGI	Katedra geoinformatiky
KML	Keyhole Markup Language
SHP	Shapefile

ÚVOD

K tomu, aby človek v dnešných časoch zistil, aké lokality najčastejšie navštevuje, akými trasami sa medzi nimi pohybuje a aký dopravný prostriedok pri tom využíva, už nie je potrebné, aby si o tom písal denník. Rovnako ani keď človek chce zistiť informácie takéhoto typu o určitej skupine ľudí v určitom meste alebo oblasti, už nie je potrebné, aby mu na tieto účely museli vyplňať dotazník. Rovnako ani nie je potrebné, aby mal jednotlivец alebo jeho respondenti neustále pri sebe GPS zariadenie, ktoré bude ich polohu sledovať. Jediná vec, ktorá je k takémuto typu sledovania potrebná je mať mobilný telefón, na ktorom sú Google Mapy a mať v nich povolené zaznamenávanie polohy.

Takýto spôsob sledovania polohy má obrovský potenciál a ten doteraz nebol poriadne využitý. Preto cieľom tejto bakalárskej práce je overiť, aké sú možnosti využitia dát služby Google Location pre časopriestorové analýzy pohybu osôb. Na splnenie tohto cieľu sú využité vedomosti a zručnosti autora z oblasti práce v štatistických programoch a geografických informačných systémoch a programovania, ktoré boli počas troch rokov štúdia na katedre geoinformatiky získané.

Na začiatku práce autor oboznamuje čitateľa so súčasným stavom riešenej problematiky stručne popisujúc doteraz použité metódy analýzy dát GPS trajektórií a dotazníkových šetrení pre identifikáciu priestorových vzorcov pohybu osôb a taktiež metódy záznamu dát služby Google Location.

V praktickej časti práce autor využíva svoje dáta, dáta vedúceho práce a dáta študentov KGI k analýzam pohybu osôb za účelom identifikácie priestorových vzorcov popisujúcich dopravné správanie. Pred samotnými analýzami vyberá tie dáta, ktoré budú pre analýzy použiteľné a výsledky analýz rôznymi spôsobmi vizualizuje.

Výsledky analýz sú na konci práce interpretované a pokiaľ je to možné, tak sú časopriestorové analýzy pohybu osôb aj porovnané so skutočnosťou.

1 CIELE PRÁCE

Cieľom bakalárskej práce je otestovať možnosti využitia dát služby Google Location pre časopriestorové analýzy pohybu osôb. Riešenie cieľa vychádza z naštudovania metód záznamu dát služby Google Location a metód analýzy dát GPS trajektórií pre identifikáciu priestorových vzorcov pohybu osôb z odbornej a vedeckej literatúry. Dáta autora práce, vedúceho práce a študentov, ktorí ich pre účely práce dobrovoľne poskytnú sú stiahnuté vo formáte JSON, následne pomocou Python skriptu prekonvertované do formátu Shapefile a v prostredí ArcMap sú z nich vybrané záznamy vhodné pre ďalšie analýzy a vizualizácie. K analýzam sú použité nástroje v programoch ArcGIS, V-Analytics, MS Excel a R Studio. Vizualizácie vo forme grafov a tabuliek sú vytvorené v programe MS Excel. Vizualizácie vo forme boxplotov sú vytvorené v programe RStudio. Vizualizácie vo forme webových mapových aplikácií sú vytvorené v ArcGIS Online pomocou nástroja WebApp Builder. Vizualizácie vo forme tlačených tematických máp sú vytvorené v prostredí ArcGIS. Vizualizácie vo forme máp líniových trajektórií pohybu sú vytvorené v programe V-Analytics. Vizualizácie sú následne interpretované so snahou identifikovať individuálne priestorové vzorce popisujúce dopravné správanie, napríklad najnavštevovanejšie miesta či najčastejšie trasy.

2 METÓDY A POSTUPY SPRACOVANIA

V tejto kapitole sú opísané všetky metódy, dáta, programy a postupy použité pri riešení cieľa práce. Postup je opísaný stručne, podrobnejšiemu popisu celej práce sa venuje kapitola Vlastné riešenie.

2.1 Použité metódy

Záznam histórie polohy bol získaný stiahnutím z Google účtu. Vedúci práce stiahol záznam svojej histórie polohy a autorovi ho poskytol. Študenti KGI boli požiadaní o poskytnutie záznamu svojej polohy prostredníctvom sociálnej siete. Hranica Accuracy, pod ktorou dáta nemajú príliš veľkú odchýlku a hranica pravdepodobnosti (confidence), nad ktorou sa záznam zhoduje s realitou boli určené pozorovaním bodového záznamu polohy a jeho porovnávaním so skutočnosťou. Dáta o pohybe boli vizualizované formou agregovaných bodových znakov, líniových znakov a heatmáp. Na štatistické vyhodnotenie záznamov boli použité tabuľky, grafy a boxploty. Mapové výstupy aj výsledky štatistických analýz boli slovné interpretované.

2.2 Použité dáta

Pri práci boli použité záznamy histórie polohy z Google Location, ktoré je možné stiahnuť vo formáte JSON. Bol použitý môj vlastný záznam polohy z obdobia od 2.5.2018 do 17.3.2019 (s výnimkou Prílohy 9, pre účely ktorej bol 25.4.2019 stiahnutý nový záznam), záznam polohy RNDr. Jaroslava Buriana, Ph.D. z obdobia od 24.5.2017 do 18.2.2019. Boli taktiež použité záznamy 15 študentov KGI, ktoré pochádzali z rôznych časových období, boli z nich však vybraté len záznamy z územia mesta Olomouc z obdobia od 1.1.2019 do 26.3.2019. Na konverziu dát do formátu SHP bol použitý skript `read_location_data.py` z GitHubu, konkrétne zo stránky Android Location Converter (Boates, 2019). Pôvodný skript však nekonvertoval do formátu SHP všetky údaje o typoch aktivity, preto bol upravený a bol vytvorený skript `read_location_data_upgrade.py` (viď podkapitola 2.4)

V mapách mojej aktivity boli ako topografický podklad zvolené hranice štátov (NUTS 2016 z Eurostatu) a krajské mestá (pre Česko z ArcČR500 v3.3, pre Slovensko z dát zo ZB GIS voľne dostupných na stiahnutie), v prípade Poľska sídla vojvodstiev (novovytvorená bodová vrstva podľa podkladovej mapy). V mapách aktivity vedúceho práce boli ako topografický podklad zvolené hranice krajov, krajské mestá a tieňovaný reliéf z dátovej sady ArcČR500 v 3.3. V mapách aktivity študentov KGI boli topografickým podkladom železnice, cesty a tieňovaný reliéf z dátovej sady ArcČR500 v 3.3.

Na tvorbu webovej stránky bol použitý vzor Industrious zo stránky <https://templated.co/>.

2.3 Použité programy

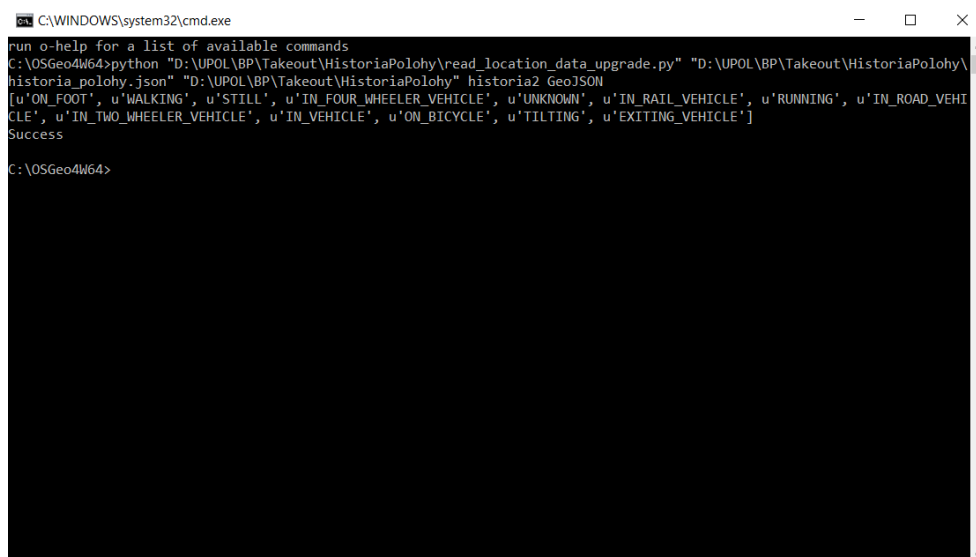
Na štruktúru záznamu histórie polohy vo formáte JSON som nahliadal prostredníctvom programu PSpad Editor. Úpravami v tomto programe boli zo stiahnutého vzoru vytvorené webové stránky práce. Skript na konverziu do formátu SHP, resp. GEOJSON bol prepísaný v programe PyScripter. Skript bol spustený pomocou príkazového riadku `OSGEO4W.bat`. Výber záznamov polohy použiteľných pre ďalšie analýzy a vizualizácie, rovnako ako aj niektoré analýzy a vizualizácie boli

prevedené v programe ArcGIS 10.6 od spoločnosti ESRI. Pomocou tohto programu boli dáta aj publikované do ArcGIS Online. Vizualizácie pohybu v rámci Olomouca prostredníctvom líniových trajektórií boli vytvorené v softvéri V-Analytics, ver.18.20.2018. Webové mapové aplikácie boli vytvorené v prostredí ArcGIS Online pomocou nástroja WebApp Builder. Konverzie z formátu GEOJSON do formátu SHP a z formátu SHP do formátu CSV boli vykonané v programe QGIS Desktop 3.2.3. Boxploty približujúce štruktúru a komplikovanosť záznamov polohy boli vytvorené v programe RStudio. Tabuľka a grafy vyjadrujúce presnosť záznamov a početnosť jednotlivých typov aktivít boli vytvorené v programe MS Excel. Poster k bakalárskej práci (Príloha 6) bol vytvorený v programe Adobe Illustrator CC 2015.

2.4 Postup spracovania

Na začiatku bola naštudovaná odborná literatúra. Boli študované hlavne články a diplomové práce, ktoré sa venovali analýzám priestorových vzorcov pohybu osôb, dostupná dokumentácia od Google, ktorá sa venuje Google Location a niekoľko krátkych internetových článkov od ľudí, ktorí skúmali štruktúru záznamu histórie polohy vo formáte JSON. Výsledkom štúdia odbornej literatúry sa venuje kapitoly súčasný stav riešenej problematiky.

Ďalším krokom bolo stiahnutie samotného záznamu histórie polohy vo formáte JSON. Ako jediný spôsob vizualizácie dát v tomto formáte bola nájdená aplikácia Location History Visualizer, ktorej sa podrobnejšie venujú kapitoly 3 a 4. Dáta boli konvertované pomocou skriptu `read_location_data.py` z GitHubu (Boates, 2019) spúšťaného pomocou príkazového riadku `OSGEO4W.bat`, ktorý bol čiastočne rozšírený a uložený ako `read_location_data_upgrade.py`. skript ponúka konverziu do formátov SHP, GEOJSON a KML. Pri konverzii do formátu SHP sa ale pravdepodobnosti niektorých typov aktivity nekonvertujú správne, preto bolo potrebné záznam najprv prekonvertovať do formátu GEOJSON (Obr. 2.1) a záznam v tomto formáte potom v programe QGIS 3.2.3 vyexportovať ako SHP. Rovnaký postup konverzie bol následne použitý aj pri dátach vedúceho práce a študentov katedry geoinformatiky.



```
C:\WINDOWS\system32\cmd.exe
run o-help for a list of available commands
C:\OSGeo4W64>python "D:\UPOL\BP\Takeout\HistoriaPolohy\read_location_data_upgrade.py" "D:\UPOL\BP\Takeout\HistoriaPolohy\historia_polohy.json" "D:\UPOL\BP\Takeout\HistoriaPolohy\historia2 GeoJSON"
[u'ON_FOOT', u'WALKING', u'STILL', u'IN_FOUR_WHEELER_VEHICLE', u'UNKNOWN', u'IN_RAIL_VEHICLE', u'RUNNING', u'IN_ROAD_VEHICLE', u'IN_TWO_WHEELER_VEHICLE', u'IN_VEHICLE', u'ON_BICYCLE', u'TILTING', u'EXITING_VEHICLE']
Success
C:\OSGeo4W64>
```

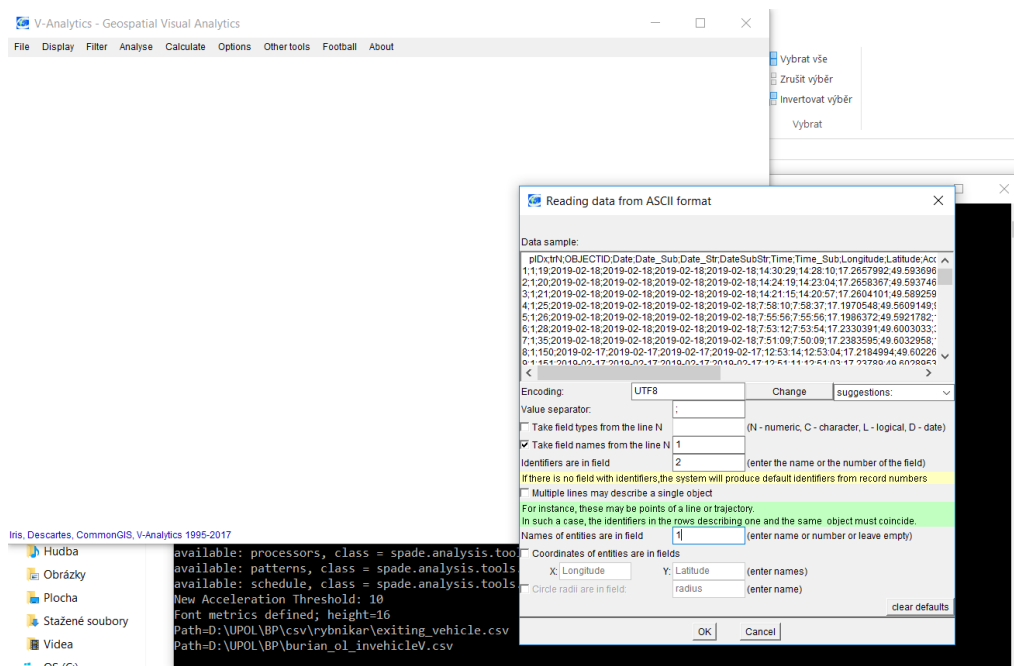
Obr. 2.1 – Spúšťanie upraveného skriptu na konverziu dát z formátu JSON

Po konverzii nasledovalo vyhodnotenie vzniknutej bodovej vrstvy. Presnosť dát bola vyhodnotená pozorovaním záznamov a ich porovnávaním so skutočnosťou. Ešte pri

štúdiu odbornej literatúry bolo zistené, že Atribút Accuracy vyjadruje odchýlku polohy záznamu od skutočnosti (nie je však jasné, v akých jednotkách) a hodnoty pri jednotlivých typoch aktivít vyjadrujú ich pravdepodobnosť (istotu). Na základe pozorovania vlastných bodových dát bolo rozhodnuté, že sa bude pracovať s dátami, ktoré majú hodnotu Accuracy 100 a menej. Ak mala aktivita v zázname hodnotu pravdepodobnosti (confidence) 50 a viac, bola vyexportovaná ako daný typ aktivity, nakoľko pri pozorovaní sa zistilo, že keby sa pracovalo len s pravdepodobnosťou 100, záznamy by boli neúplné a keby zas bol ako aktivita zvolený každý záznam s jej pravdepodobnosťou nad 25, novovzniknuté dáta by často neodpovedali realite. Podrobnejší popis vyhodnocovania zhodnosti záznamu s realitou je uvedený v kapitole Vlastné riešenie. Pri dátach od vedúceho práce a dátach spolužiakov boli už automaticky vybrané záznamy s Accuracy väčšou alebo rovnou 100 a typ aktivity bol určený, pokiaľ mal v zázname pravdepodobnosť 50 a viac. Dáta študentov KGI boli spojené do jedného súboru, z nich boli vybrané záznamy čisto pre mesto Olomouc a z nich záznamy z času od 1.1.2019 do 26.3.2019.

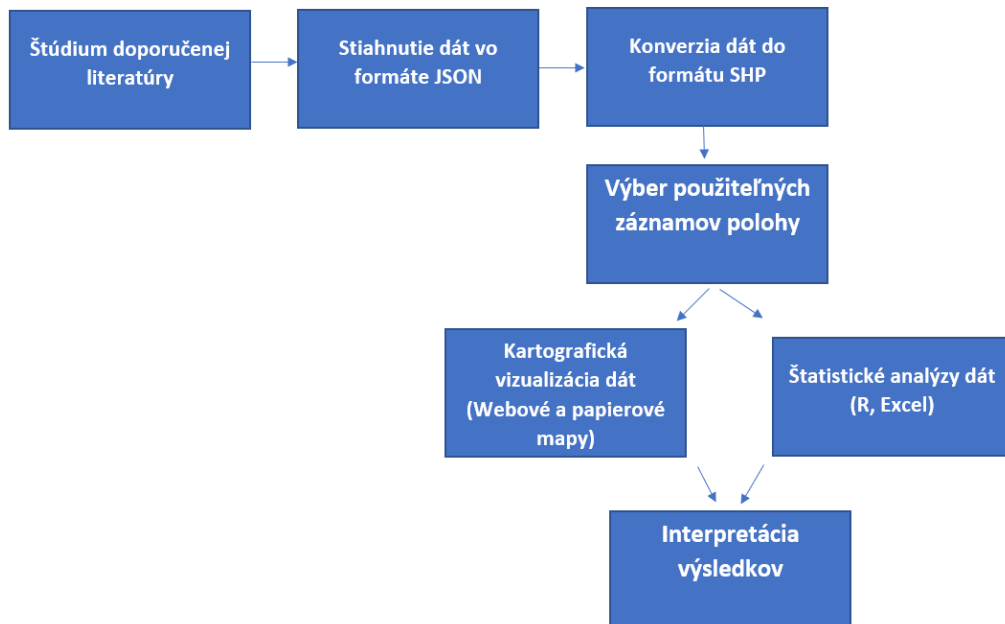
Nad novovzniknutými dátami boli prevedené štatistické analýzy v programoch MS Excel a RStudio. Cieľom štatistických analýz v MS Excel bolo zistiť, aké presné sú dáta a aká je početnosť jednotlivých typov aktivity v záznamoch. Pre účely štatistických analýz v RStudio boli dáta prekonvertované do formátu CSV a záznam v tomto formáte bol následne do RStudio nahraný. Cieľom štatistických analýz v RStudio bolo zistiť, ako sa v záznamoch prekrývajú jednotlivé typy aktivity. Interpretáciou výsledkov štatistických analýz sa zaoberá kapitola Výsledky práce.

Následným krokom bola vizualizácia priestorových vzorcov pohybu osôb. Bola prevedená v programe ArcGIS 10.6, kde boli vytvorené heatmapy pomocou nástroja Kernel Density, V Analytics, kde boli zvizualizované trajektórie pohybu v meste Olomouc a WebApp Builder v ArcGIS Online, kde boli vytvorené mapové aplikácie. Pred nahraním do programu V-Analytics boli dáta prekonvertované do formátu CSV a čiastočne upravené (Obr. 2.2).



Obr. 2.2 – Nahrávanie CSV záznamu do V-Analytics

Na záver boli interpretované výsledky štatistických analýz a kartografických vizualizácií. Interpretáciou štatistických analýz sa zistilo, ako veľmi sa hodnoty pravdepodobnosti jednotlivých typov aktivity prekrývajú a interpretáciou kartografických vizualizácií sa určilo, kde sa pohybovali autor práce, vedúci práce a študenti KGI a aké typy aktivity vykonávali. V prípade autora práce a vedúceho práce bola aj snaha porovnať výsledky kartografických vizualizácií so skutočnosťou.



Obr. 2.3 – Postup pri tvorbe bakalárskej práce

3 SÚČASNÝ STAV RIEŠENEJ PROBLEMATIKY

Analýza priestorových vzorcov pohybu osôb bola riešená už vo veľa prácach v minulosti (Burian 2018, Wang 2017, atď.), avšak nebola nájdená žiadna práca, ktorá by sa zaoberala práve analýzou a vizualizáciou dát získaných zo služby Google Location. V nasledujúcich podkapitolách sú popísané doterajšie spôsoby analýzy pohybu osôb pomocou dát získaných pomocou dotazníkových šetrení, prípadne z navigačných a iných elektronických nástrojov. Následne sú popísané princípy fungovania Google Location ako aj možnosti získania dát z Google Location a následnej práce s nimi.

3.1 Analýzy pohybu osôb z dát získaných dotazníkovým šetrením

Analýzami pohybu osôb pomocou dát získaných z pozorovania a dotazníkov sa na Katedre geoinformatiky Univerzity Palackého v Olomouci zaoberala vo svojej bakalárskej práci Vondráková, 2007. V rámci jej práce bol pozorovaný pohyb osôb v Olomouci, konkrétne na sídlisku Černá cesta, na Hornom námestí a v OC Haná. Zber dát trval štyri týždne, meralo sa od šiestej do dvadsiatej hodiny. Nezmeriaval sa len na pohyb ľudí do a z sledovanej lokality, ale aj na štruktúru populácie. Okrem toho bol v jej práci použitý aj sekundárny zdroj dát, a to údaje poskytnuté spoločnosťou Euro Mall Centre Management s.r.o. (správca OC Haná) a Magistrátom mesta Olomouc (informácie o trvalom bydlisku osôb na Hornom námestí a sídlisku Černá cesta). Údaje získané v jej práci boli ďalej štatisticky vyhodnocované a kartograficky spracované. Kartograficky vizualizované boli kvalitatívne, ako aj kvantitatívne charakteristiky pohybu mestskej populácie. Kvalitatívne charakteristiky boli vyjadrené formou bodovo lokalizovaných diagramov. Kvantitatívne charakteristiky boli vyjadrené formou diagramov a interpolácie.

Dotazníkové dáta k analýze pohybu osôb vo svojej práci využil aj Frantál, 2012. Zapodieval sa rôznymi prejavmi ľudského správania v čase a priestore so špecifickým zameraním na každodenné aktivity a mobilitu v urbánnom prostredí. Na úvod predstavil teoretické koncepty a metódy používané vo výskume priestorového správania. Venoval sa problematike spracovania, analýzy a vizualizácie časopriestorových dát v prostredí geografických informačných systémov (GPS) a predstavil niektoré typické príklady geovizualizácií dát ako v dvojrozmernom, tak i v trojrozmernom priestore. Tvrdil, že geografia času je jedným z najčastejšie aplikovaných konceptov či prístupov k výskumu a analýze priestorového správania jedincov. Dôležitým konceptom súvisiacim s cestami sú podľa neho zväzky (bundles). Zväzky predstavujú časti časopriestoru, v ktorých sa v jednej stanici stretávajú dve alebo viac individuálnych ciest (jedincov či materiálnych objektov). Dáta v jeho výskume boli získavané pomocou harmonogramov časopriestorových aktivít vyplňanom jednotlivcami. V Brne sa do prieskumu zapojilo 150 osôb, v Olomouci 50 študentov. V Brne boli kartografickým výstupom výskumu mapy priestorovej distribúcie a funkcie staníc pre študentov. V Olomouci boli kartografickým výstupom výskumu mapy intenzity úsekov ciest a mapy spôsobu pohybu po vybraných cestách.

Burian a kol., 2018, porovnával Olomouc a Ostravu z pohľadu faktorov ovplyvňujúcich priestorové a časové vzory, voľbu typu dopravy a dopravné správanie. Boli skúmané postoje a motivácie k rôznym druhom prepravy u viac než 500

respondentov v každom meste. Časové vzory v oboch mestách sú podobné a nezávisia na veľkosti mesta alebo jeho priestorovej štruktúre. Respondenti mali opísať svoje normálne trasy v priebehu dňa. Mali opísať začiatkové a koncové body svojich ciest, dĺžku trvania, použité dopravné prostriedky, účel a frekvenciu. Väčšina respondentov tiež opísala svoju motiváciu používať auto alebo verejnú dopravu, pretože výskum bol primárne založený na porovnávaní áut a verejnej dopravy. Rozhovory prebiehali na uliciach skúmaných miest a priemerná dĺžka ich trvania bola 20 minút. Pohyb po meste bol zvizualizovaný pomocou softvéru V-Analytics. Bolo zistené, že pomocou časového vzorca správania populácie je možné identifikovať širokú škálu informácií.

Naserian a kol., 2018, rozdelil cestovateľov do štyroch skupín na rodinu, priateľov, páry a samostatných jednotlivcov a sú skúmané ich pohyby z jedného miesta na druhé. Prieskum bol robený na letisku v Guangzhou, kde sa 1000 skupín, prípadne jednotlivcov pýtali, kam cestujú. Bol definovaný nový vzorec frekvencie, GFSP, ktorý bral ohľad na cestovateľskú skupinu užívateľov. Bol navrhnutý nový personalizovaný predikčný rámec na predpoveď ďalšej polohy užívateľa pre aplikácie ako „služby založené na polohe“ (location-based services). Hlavnou myšlienkou modelu bola nová predikčná stratégia vyhodnocujúca skóre novej polohy pre daného užívateľa ťažením vzorcov pohybu užívateľov podľa všeobecných vlastností a vlastností špecifických pre skupinu. Na zistenie cestovných skupín z časopriestorových trajektórií bol použitý nový objav skupinových vzorov berúci ohľad na ľudské správanie pri pohybe. Následne bol podľa informácie o jednotlivcovi objavený typ skupiny. Bola to prvá práca, ktorá sa sústreďuje na predpoveď ďalšej polohy pomocou získavania dát o trajektórii, ktorá berie ohľad na skupiny, s ktorými ľudia cestujú.


3.2 Analýzy pohybu osôb z dát získaných z GPS prijímačov a sociálnych sietí

Oproti dotazníkovému šetreniu, pri ktorom autorovi práce zostáva len spoliehať sa na dôveryhodnosť respondentov, sa práca nad dátami z GPS prijímačov, mobilných zariadení a sociálnych sietí rozhodne javí ako lepšia alternatíva, zvlášť v dnešnej dobe, keď už väčšina ľudí vlastní nejaké zariadenie s GPS prijímačom.

3.2.1 Študentské práce

Jarcovják, 2013, vo svojej práci uviedol, že vzrast používania sociálnych sietí a služieb poskytuje užitočný zdroj, kde dáta o lokácii, ľudskej aktivite alebo sociálnych vzťahoch vytvárajú ďalšie možnosti k sledovaniu pohybu obyvateľov a zachycujú tak dynamiku mesta. Vo svojej práci sa venoval testovaniu aplikácie Foursquare pre sledovanie pohybu osôb v Olomouci. Foursquare, aplikácia pre mňa pre prečítaním práce úplne neznáma, je v práci uvedená ako jedna z piatich najviac využívaných geosociálnych sietí dostupných v Českej republike. Užívatelia tejto aplikácie sa nahlasujú na miestach, na ktorých sa práve nachádzajú a preto je možné dáta z aplikácie využiť na analýzy pohybu osôb. Pre zaujímavosť som si aplikáciu sám skúsil stiahnuť na Google Play. Má veľmi prívetivé užívateľské rozhranie a ľahko sa s ňou pracuje, avšak v dnešných časoch sú pre ňu Google Mapy príliš veľkou konkurenciou. Výskum Jarcovjáka trval od augusta 2012 do marca 2013. 26 užívateľov aplikácie Foursquare a 12 študentov katedry geoinformatiky mu svoje dáta poskytlo vo formáte KML, ktorý Foursquare poskytuje k uchovaniu vlastnej aktivity užívateľa. Nad získanými dátami boli v programe ArcGIS 10.1 prevedené analýzy pomocou nástrojov

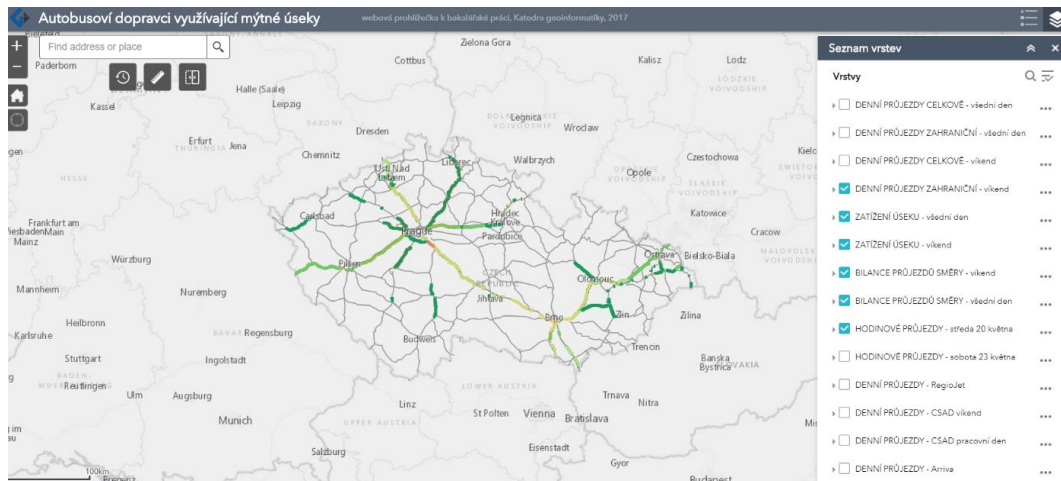
Collect Events a *Kernell Density*. Pomocou sieťovej analýzy bola v tomto programe vytvorená optimálna trasa medzi miestami, na ktorých sa užívatelia aplikácie nahlásili (Obr. 3.1). V programe MS Excel boli vytvorené vizualizácie formou grafov.



Obr. 3.1 Vizualizácia predpokladaného pohybu užívateľov aplikácie Foursquare v práci Jarcovjaka

Fusková, 2014, vo svojej práci pracovala s dátami zo sociálnych sietí Facebook, Twitter a LinkedIn. Dáta do jej práce boli získané z API pomocou data miningu. Uložené boli do formátu JSON, na čo boli následne prevedené do formátu GEOJSON a geokódované. Pri práci sa však autorka nezameriava na analýzu a vizualizáciu pohybu osôb, ale len na geovizualizáciu príspevkov na sociálnej sieti Twitter, takže pre moju bakalársku prácu informácie z tejto práce nemajú veľký význam.

Trochu iným spôsobom zberu dát, a to prostredníctvom mýtnych brán, sa vo svojej práci zaoberal Roubalík, 2017. Jeho práca sa zaoberala využitím mýtnych úsekov autobusovými dopravcami a bola primárne zameraná na diaľkovú autobusovú dopravu a verejnú linkovú dopravu. Tarifnú tabuľku mýtnych úsekov do práce mu poskytlo Ředitelství silnic a dálnic, vrstvu mýtnych úsekov mu poskytlo Central European Data Agency a dáta intenzít dopravy získal z celoštátneho sčítania dopravy z roku 2010. Dáta štatisticky spracoval pomocou kontingenčnej tabuľky. Štatistické spracovanie zahŕňalo stanovenie priemernej dennej intenzity prejazdov, stanovenie miery vyťaženia úseku, zrovnanie zaťaženia smerov úseku, stanovenie zaťaženia úsekov, stanovenie intenzity prejazdov hraničnými priechodmi, intenzitu prejazdov individuálnych dopravcov a zrovnanie priemerných intenzít s celoštátnym sčítaním dopravy z roku 2010. Získané výsledky vizualizoval formou tabuliek a grafov a taktiež v programe ArcMap pomocou metód tematickej kartografie, konkrétne metódou líniových znakov a štruktúrneho kartodiagramu. Vytvoril tiež webovú aplikáciu v ArcGIS Online obsahujúcu 18 mapových vrstiev (Obr. 3.2)



Obr. 3.2 Webová prehliadačka vytvorená ako súčasť práce Štěpána Roubalíka.

Mapovaniu pohybu osôb sa vo svojich záverečných prácach nevenovali len študenti olomouckej katedry geoinformatiky. Pojsl, 2014, z Jihočeskej univerzity v Českých Budějoviciach sa vo svojej bakalárskej práci snažil zmapovať každodennú priestorovú mobilitu v prostredí mesta Strakonice. Behom výskumu analyzoval dáta získané dotazníkovým šetrením a záznamy vytvorené GPS lokátormi. Obe metódy boli do výskumu zapojené súbežne. Stanovil predpoklad, že pravidelné cesty zahrňajúce dochádzky do práce a do školy budú zahrňať 40% všetkých ciest a tento predpoklad sa mu potvrdil. Jeho druhým predpokladom bolo, že ľudia strávia denne cestovaním 40 až 60 minút. Tento predpoklad bol taktiež potvrdený nameranými 44 minútami. Prepojenie klasického zápisu s dotazníkmi a GPS záznamov sa ukázalo ako veľmi efektívne, ide totiž o kombináciu dvoch vzájomne sa dopĺňajúcich metód, ktorá zvyšuje presnosť a jednoznačne tak pridáva na kvalite celej práce.

3.2.2 Práce zahraničných expertov

Využitím mobilných dát k výskumu cestovateľského správania sa zaoberali Wang a kol., 2017. Na začiatku práce diskutovali potenciál dát z mobilných telefónov v postupujúcom výskume cestovateľského správania a vyzdvihli výzvy, s ktorými si ešte musia ľudia poradiť. Podľa nich v dobe „Veľkých dát“ (Big data) môžu byť tradičné zdroje dát pre prieskum cestovateľského správania (travel behaviour) nahradené dátami čipových kariet, údajmi o trajektóriách taxíkov, údajmi snímačov na cestách a dátami z mobilných telefónov. Okrem GPS prijímačov sú ďalšími možnosťami lokalizácie mobilných prijímačov Wi-Fi positioning (v budovách) a Bluetooth positioning. . Pisali, že ľudské cestovateľské správanie vykazuje veľkú časovú a priestorovú pravidelnosť. Indikátorom snažiacim sa posúdiť náhodnosť ľudského cestovateľského správania bola Shannonova entropia – väčšia entropia znamená, že vzorec je náhodnejší a menej predpovedateľný. Tvrdili taktiež, že trajektórie ľudského pohybu sa viac podobajú kruhu než linii a miesta ľuďmi navštevované sú roztrúsené a nie lineárne distribuované. Ďalším spôsobom znázornenia ľudského cestovateľského správania môže byť napríklad konvexná obálka. V porovnaní so samotnými GPS jednotkami majú mobilné telefóny niekoľko výhod. Sú dnešnou populáciou častejšie používané, majú väčšiu dosiahnuteľnú veľkosť vzorky a často sú vybavené senzormi ako akcelerometer alebo magnetometer. V porovnaní s inými tradičnými dátami majú dáta z mobilných telefónov mnoho unikátnych atribútov a výhod, napríklad monitoring ľudského pohybu v reálnom čase, pokrytie takmer celej populácie a detailné informácie o pohybe. Vďaka týmto atribútom majú dáta z mobilných telefónov potenciál identifikovať viac vzorcov

cestovateľského správania, ktoré tradičné dáta z výskumov nedokážu odhaliť. Tradičné prieskumy väčšinou pokrývajú len normálnych obyvateľov, zatiaľ čo dáta z mobilných telefónov môžu poskytnúť dáta o priestorových vzorcoch pohybu turistov. Dáta z mobilných telefónov tiež ponúkajú potenciál obohatiť výskum o dáta o zmenách cestovateľského správania spôsobených zmenou práce, bydliska či ročného obdobia. Na druhej strane, štatistické modely majú veľké požiadavky na presnosť a komplexnosť dát, s ktorou môžu mať dáta z mobilných telefónov problémy. Tieto dáta majú tiež obrovský objem, veľa rozmerov a neštruktúrované formy a tradičné modely ich nemusia zvládnuť, rovnako ako nedokážu zachytiť ďalekonosné korelácie a závislosti medzi jednotlivcami, ktoré sú prirodzenou súčasťou dát z mobilných telefónov. Vývoj nových teórií a modelov pre „simuláciu cestovateľského správania“ (Travel behavior simulation) s dátami z mobilných telefónov by mal byť preto novou výzvou.

Sohn a kol., 2006, vo svojej práci opisovali, ako môžu byť „hrubozrnné“ (coarse-grained) dáta globálneho systému mobilných komunikácií (GSM) použité na rozpoznanie užívateľskej mobility. S nemodifikovaným GSM telefónom môžeme rozpoznať, či užívateľ kráča, šoféruje, alebo zostáva na mieste s 85% presnosťou. V experimente boli po dobu jedného mesiaca zbierané dáta od troch ľudí. Svoje aktivity si zapisovali do denníka v telefóne Audiovox SMT 5600 (starý tlačidlový, v tej dobe zrejme šlo o moderné zariadenie). Na meranie krokov používali zariadenie Omron Healthcare HJ-112 pedometer. Ako možné spôsoby využitia výskumu uviedli koordinovanú starostlivosť pre starých ľudí podporovanú počítačom a social-mobile applications, ktoré pomôžu ľuďom komunikovať tým, že budú vedieť svoju polohu svojich priateľov a známych. Na rozdiel od iných systémov rozpoznávania aktivity, ktoré môžu vyžadovať, aby osoba nosila špeciálne zariadenie, v ich výskume užívatelia jednoducho používali mobilné telefóny rovnako ako počas normálnych dní. Výsledky ukázali, že už v čase napísania článku mobilné telefóny bez špeciálnych senzorov alebo zariadení dokázali rozlíšiť ľudské aktivity, poskytujúc ľuďom odhad ich vzorcov pohybu v priebehu dňa.

Gianotti a kol. 2006, sa venovali „analýze priestorových vzorcov trajektórií“ (Trajectory pattern mining). Predstavili vzorce trajektórií ako stručné opisy cestovného správania ako v priestore, tak aj v čase. Hlavným objektom ich výskumu bola trajektória opisujúca pohyb objektu. Práca sa snažila zistiť užitočnosť analýzy priestorových vzorcov trajektórií (Trajectory pattern mining) v analýze toku dopravy v metropolitnej oblasti. V opísanom výskume boli využité GPS dáta z 273 nákladných áut v Aténach. Bolo objavených niekoľko vzorcov ich trajektórie. Na syntetických, vygenerovaných dátach boli testované algoritmy Static_RoI_T-pattern a Dynamic_RoI_T-pattern. Vstupmi do Dynamic_RoI_T-pattern algoritmu boli trajektórie, mriežka, minimálny prah podpory/hustoty, priemer pre priestorové susedstvá a časový prah. (Obr. 3.3)

Algorithm: Dynamic_RoI_T-pattern($T_{in}, \mathcal{G}_0, \delta, \epsilon, \tau$)

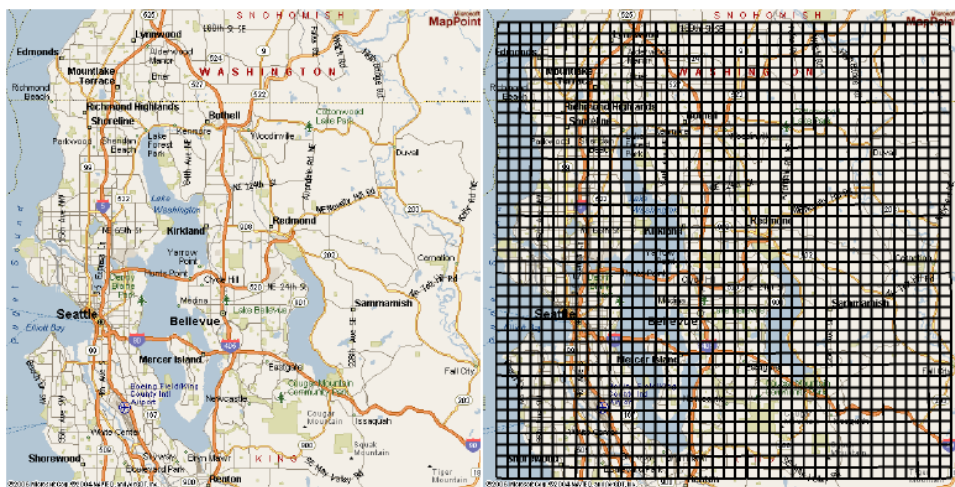
Input: A set of input trajectories T_{in} , a grid \mathcal{G}_0 , a minimum support/density threshold δ , a radius for spatial neighborhoods ϵ , a temporal threshold τ .

Output: A set of couples (S, \mathcal{A}) of sequences of regions with temporal annotations.

```
1.  $L = 0; T_0 = \{(T_{in} \times \{\emptyset\}, \{\})\};$ 
2. while  $T_L \neq \emptyset$  do
3.    $T_{L+1} = \emptyset;$ 
4.   foreach  $(T, prefix) \in T_L$  do
5.     if  $|prefix| \geq 2$  then
6.        $\mathcal{A} = \text{ExtractFrequentTimings}(T);$  ([5])
7.       Output  $(prefix, \mathcal{A});$ 
8.        $T = \text{PruneEmptyAnnotations}(T, \mathcal{A});$  ([5])
9.        $\mathcal{G} = \text{ComputeDensity}(T, \mathcal{G}_0, \epsilon);$  (Sect.4.2.1)
10.       $RoI = \text{PopularRegions}(\mathcal{G}, \delta);$  (Sect.4.2.2)
11.       $\mathcal{D} = \text{Translate}(T, RoI);$  (Sect.4.1)
12.      foreach  $r \in RoI$  do
13.        if  $\text{support}_{\mathcal{D}}(r) \geq \delta$  then
14.           $\mathcal{D}' = \text{ExtendProjection}(\mathcal{D}, r);$  ([5])
15.           $T' = \{ (traj, \mathcal{A}') \mid (traj, \mathcal{A}) \in T$ 
16.                 $\wedge (S', \mathcal{A}') \in \mathcal{D}' \wedge traj.ID = S'.ID$ 
17.                 $\wedge traj' = \text{Cut}(traj, \mathcal{A}') \}$ 
18.           $T_{L+1} = T_{L+1} \cup \{(T', \text{append}(prefix, r))\};$ 
19.    $L++;$ 
```

Obr. 3.3 Ukážka algoritmu Dynamic_RoI_T-pattern

Krumm a kol., 2006, písali o metóde „predestinácie“ (predestination), ktorá využíva históriu destinácií vodiča spolu s dátami o správaní vodiča k predpovedi, kam sa vodič ďalej vyberie. Správanie šoféra zahŕňa destinácie, účinnosť šoférovania a dĺžky výletov. Okrem lokalít navštívených v minulosti metóda predestinácie brala ohľad na pravdepodobnosť návštevy nových lokalít na základe trendov v dátach a vlastností tých lokalít. V ich výskume boli použité dáta zo 169 rôznych subjektov. Takmer všetky subjekty pochádzali zo Seattle v USA. Subjekty mali GPS prijímač dva týždne vo svojom aute. Dáta od nich získané boli rozdelené na diskrétne výlety. Zmazané boli tie výlety, ktorých rýchlosť nepresiahla 25 míľ za hodinu, aby boli odstránené pešie a cyklistické výlety, na ktorých mali subjekty GPS zariadenie so sebou. Taktiež boli odstránené výlety kratšie než 1 km, prípadne obsahujúce menej než 10 GPS bodov. Celkový počet výletov bol nakoniec 7 335. Na výletoch z databázy GPS trás bol testovaný predestinačný algoritmus. Nad mapou okolia mesta Seattle bola vytvorená mriežka, v ktorej mal jeden štvorec dĺžku hrany 1km a obsahovala spolu 1600 buniek (Obr. 3.4). Bola počítaná pravdepodobnosť toho, že bunka sa stane novou destináciou. Táto pravdepodobnosť bola okrem miest navštívených v minulosti počítaná aj na základe dát o pokryve Zeme z USGS. Najprv bolo predpokladané, že subjekt navštívi miesto, na ktorom už v minulosti bol a lokalitám, ktoré nenavštívil, bola pridaná nulová pravdepodobnosť, potom sa počítalo aj s miestami, ktoré užívateľ ešte nenavštívil.



Obr. 3.4 Mriežka vytvorená nad okolím mesta Seattle

Salomon a kol., 2017, ukázali, ako môže byť história polohy používateľa spracovaná na získanie najrelevantnejších navštívených lokalít a na modelovanie užívateľského profilu pomocou váženej konečnej automatizácie (Weighted finite automation). Písali, že sociálne siete povoľujú svojim užívateľom registrovať svoju polohu bez potreby interakcie a tento spôsob nazvali všadeprítomné vypočítavanie (Ubiquitous computing). Bola navrhnutá metóda extrakcie užívateľských profilov z ich histórie polohy. Prvým krokom je premena trajektórií na sekvencie navštívených oblastí záujmu. Boli to oblasti, v ktorých užívateľ strávil nejaký čas. Následne niekoľko záznamov toho istého bodu vytvorilo región záujmu. Potom bola použitá metóda zhlukovania založená na hustote (DBSCAN). Následne sú už vytvorené samotné užívateľské profily. Akonáhle bol vytvorený užívateľský profil, mohol byť vytvorený aj popis užívateľov. Metóda bola otestovaná na dátach z Geolife GPS trajectory datasetu od 182 užívateľov hlavne z Číny, ale aj z USA a Británie.

Allahviranloo a kol., 2015, sa nezameriavali len na zber časopriestorových, ale aj socioekonomických dát. Vo svojom článku opisovali prácu s dátami z California household travel survey z rokov 2000 a 2001. Pracuje sa s dátami od 31 511 jednotlivcov, čo je o dosť väčší počet oproti iným výskumom, na ktoré som zatiaľ narazil. Cieľom ich práce bolo odvodzovanie vzorcov trajektórií a časopriestorová distribúcia cestovateľov v mestských oblastiach. Snažili sa zistiť závislosť socioekonomických atribútov a vzorcov aktivít. Klasifikovali aktivity podľa atribútov do rôznych kategórií podľa typu aktivity (*domáca, pracovná, údržbová, prispôsobivá, vyzdvihnutie/vysadenie*), času príchodu (*pred obedom, medzi obedom a piatou, po piatej*), trvania aktivity (*menej ako 2 hodiny, 2-5hodín, viac než 5 hodín*), vzdialenosti od domu (*menej ako 10 míľ, 10-20 míľ, nad 20 míľ*) a vzdialenosti od miesta predchádzajúcej aktivity (*menej ako 10 míľ, 10-20 míľ, nad 20 míľ*). Pomocou algoritmu „adaptívneho zvýšenia“ (Adaboosting algorithm) tieto kategórie kombinovali a vzniklo spolu 405 rôznych tried. Dôvodom výberu tohto algoritmu bol krátky čas výpočtu a vysoká presnosť. Autori verili, že streaming z GPS location senzorov môže byť využitý na vývoj modelov založených na aktivitách, ktoré môžu byť využité v procese plánovania dopravy.

Liao, a kol., 2006, prezentovali koncept osobnej mapy, ktorá bola prispôbená jednotlivcovi na základe jeho správania. Osobná mapa obsahovala miesta významné pre jednotlivca ako domov, miesto práce, nákupné centrá, miesta stretnutí a trasy, po ktorých sa často pohybuje. V článku bola osobná mapa použitá na rozlíšenie užívateľských aktivít, predpoveď budúcich pohybov užívateľa a usúdenie, že jeho bežná rutina bola narušená, napríklad keď zabudol vystúpiť z autobusu. Dáta boli zbierané pomocou GPS jednotiek, ktoré užívateľia nosili. Boli vytvorené dva datasety. Prvý obsahoval dáta od jednej osoby zbierané za 4 mesiace, druhý dáta od piatich ľudí, ktoré boli zbierané 1 týždeň. Vo výskume bola použitá diskriminačná relačná Markovova sieť na extrahovanie významných miest a ich pomenovávanie a dynamická Bayesovská sieť na naučenie transportačných rutín, odvodzovanie cieľov a potenciálnych chýb v reálnom čase. Systém nielen vyberal miesta, ale aj rozpoznával aktivity s nimi spojené. Podľa autorov je segment definovaný počiatočnou lokalitou, konečnou lokalitou a použitým dopravným prostriedkom. Bol tu predstavený systém, ktorý dokáže budovať osobné dáta z GPS senzorov automaticky. Využitím práce môžu byť osobné riadiace systémy pre ľudí s poruchami kognitívnych schopností.

Ye, a kol., 2009, tvrdili, že zvyšujúca sa dostupnosť dát o histórii polohy jednotlivcov nám prináša výzvy ako aj príležitosti ako objaviť ich hodnotu. Z dát o histórii polohy môže byť objavený životný štýl jednotlivca. Vďaka tomu môže mobilný telefón ktorý

pozná životné vzorce užívateľa, pomôcť užívateľovi napríklad naplánovať cestu do práce. Predstavujú normálnu formu životného vzorca (*LP-normal form*) určenú k formalizácii vyjadrenia životných vzorcov a uľahčeniu ťažobného rámca. Ďalej predstavili rámec dobývania životných vzorcov (*LP-mine frame*) určený k efektívnemu extrahovaniu životných vzorcov zo surových GPS dát. Ako vidieť z hierarchie životných vzorcov (Obr. 3.5), životný vzorec môže byť podmienený alebo nepodmienený. Z podmieneného životného vzorca sa stáva životné pravidlo. Nepodmienený životný vzorec môže byť sekvenčný alebo nesequenčný. Boli vykonané extenzívne experimenty s použitím GPS dát zbieraných dobrovoľníkmi v reálnom svete v priebehu 6 mesiacov na verifikovanie efektivity rámca dobývania životných vzorcov. Dáta boli získané z 28 veľkých miest v Číne a ďalších miest v USA, Južnej Kórei a Japonsku. Získané vzorce boli vizualizované pomocou GeoLife aplikácie formou webovej mapy.

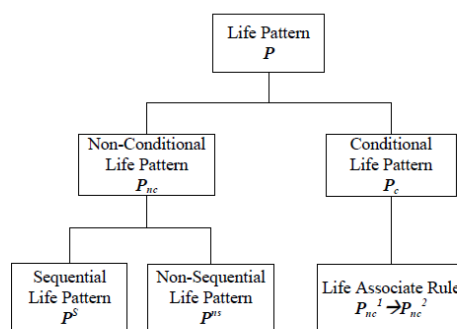


Fig. 1 Hierarchy of life patterns

Obr. 3.5 – Hierarchia životných vzorcov

Thudt a kol., 2013, písali, že automaticky zbierané časovo označené lokalizačné dáta neodrkadľujú spôsob, akým si ľudia svoje výlety pamätajú. Vo svojej práci *Visits* (návštevy) vytvorili vizualizáciu automaticky zbieraných časopriestorových dát odrzkadľujúcu súčasné vedomosti o tom, ako si ľudia prirodzene pamätajú svoje cesty. Vyvinuli *map-timelines*, vizualizačnú techniku integrujúcu časové a priestorové informácie k zobrazeniu histórií výletov ako sérií navštívených miest. Definujú miesta (*places*) ako oblasti obsahujúce jeden alebo viac lokalizačných bodov, nezávisle od časovej informácie a pobyty (*stays*) ako časové rámce strávené na určitom mieste, ktoré majú počiatkový čas, trvanie a konečný čas. Ich zhlukujúci algoritmus spája prihlásené polohy do pobytov. *Visits* primárne pozostávali z dvoch položiek, a to z centrálne umiestnenej *map-timeline* a prehľadovej mapy v ľavom donom rohu (Obr. 3.6). Pohybmi myši môže užívateľ skúmať napríklad prihlásené lokality. Aplikácia bola napísaná v jazyku *Actionscript 3.0*, dáta do nej sú získané v *Open Street Map* pomocou *MapQuest API*. Ich koncept by mohol byť použitý na rozličné typy časovo a polohovo založených dát, napríklad záznamy historických ciest, nasadenie vojsk počas vojen, históriu objavovania nových krajín alebo teritoriálny rozvoj krajín a miest v priebehu času. Osobne ma táto práca zaujala najviac zo všetkých prác na tému vizualizácie časopriestorových dát, ktoré som si prešiel.



Obr. 3.6 – História polohy používateľa v priebehu šiestich mesiacov v aplikácii Visits

3.3 Google história polohy

Podľa Support.google.com, 2018, Google história polohy ukladá polohu užívateľa na každom zariadení, na ktorom je používateľ prihlásený do Google účtu, užívateľ má zapnutú históriu polohy a zariadenie má zapnuté zaznamenávanie polohy. Prostredníctvom histórie polohy môže užívateľ vidieť personalizované mapy, odporúčania na základe miest, ktoré už navštívil, služba mu dokáže pomôcť nájsť svoj telefón a môže vďaka nej získať aj informácie o aktuálnej cestnej premávke. Na svojej časovej osi má užívateľ možnosť vidieť miesta, ktoré navštívil a informácie o svojej polohe môže upravovať ako aj vymazávať. Rovnako ľahko ako zapnúť môže užívateľ históriu polohy na svojom zariadení aj kedykoľvek vypnúť, prípadne nastaviť, z ktorých zariadení, na ktorých je užívateľ prihlásený, môže byť zaznamenávaná jeho poloha. Keď je história polohy vypnutá, nová informácia o polohe sa už nezaznamenáva, ale predošlá aktivita z nej nie je automaticky vymazaná. Celú históriu, prípadne jej časť je možné vymazať jednoducho, prostredníctvom nastavení časovej osi. Zariadenie môže posielať informácie o tom, čo v histórii polohy funguje a čo nefunguje. Informácie, ktoré môže zariadenie vysielat' za účelom zlepšenia presnosti histórie polohy zahŕňajú kvalitu a dĺžku pripojení k mobilným sieťam, GPS, sieťam Wi-Fi alebo Bluetooth, stav nastavení polohy, či nabitie batérie.

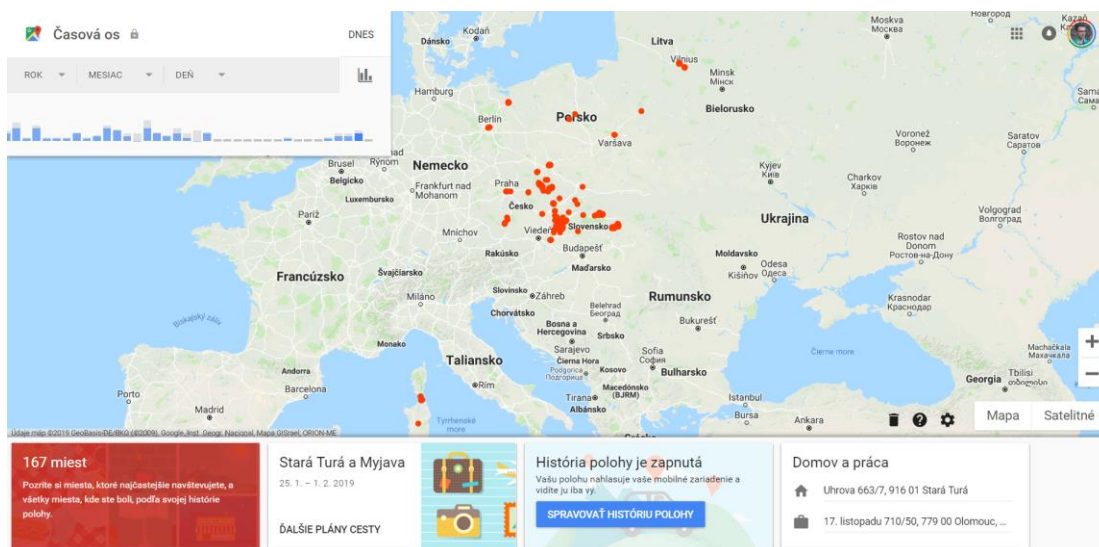
Po prihlásení do svojho Google účtu si môže užívateľ na svojej časovej osi nájsť buď celkovú históriu svojej polohy od povolenia jej zaznamenávania (Obr. 3.7), históriu polohy v určitom mesiaci (Obr. 3.8) alebo históriu svojej polohy v určitý deň s farebným rozlíšením dopravných prostriedkov, ktorými sa pohyboval. (Obr. 3.9). Užívateľ môže buď stiahnuť záznam z určitého dňa do KML alebo stiahnuť kópiu všetkých vlastných údajov do formátu JSON alebo KML.

Záznam histórie polohy vo formáte JSON je možné nahrat' do webovej mapovej aplikácie Location History Visualiser, kde sa z neho automaticky vytvorí heatmapa. Aplikácia používa balík *leaflet.js* na renderovanie interaktívnej mapy, *leaflet.heat* na renderovanie heatmapy, *filestream*, aby si vedel poradiť s gigantickými Google Takeout súbormi, *oboe.js* na spracovávanie gigantických súborov a *browserify*, aby filestream správne fungoval. Aplikácia je voľne šíriteľná pod GNU GPL licenciou (Patt, 2019).

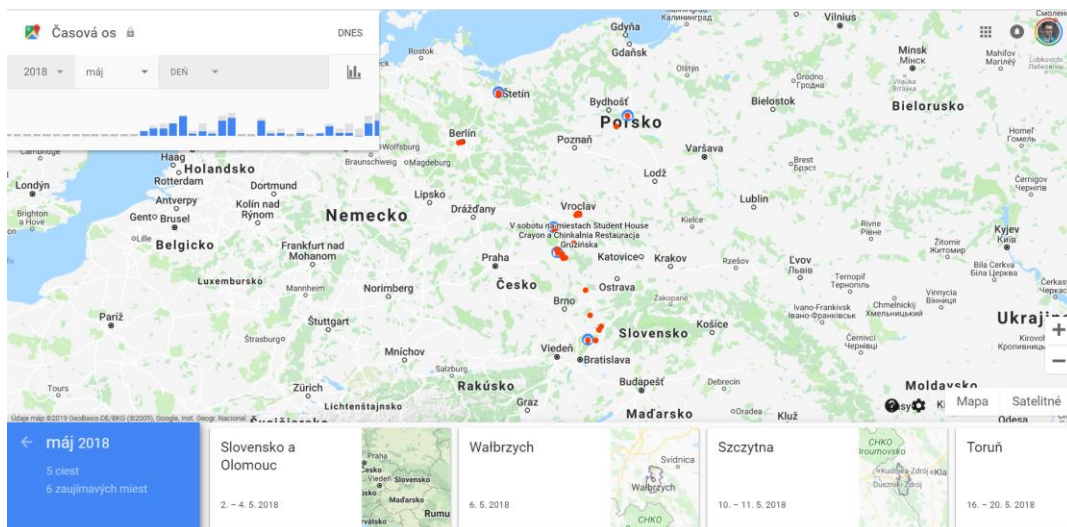
Google Developers, 2019 píšú, ako Google definuje niektoré typy aktivity. `IN_VEHICLE` znamená, že zariadenie je v dopravnom prostriedku, napríklad v aute.

ON FOOT znamená, že užívateľ kráča alebo beží. RUNNING znamená, že užívateľ beží. STILL znamená, že zariadenie sa nehýbe. TILTING znamená, že uhol zariadenia vzhľadom ku gravitácii sa výrazne zmenil. UNKNOWN znamená, že nebolo možné rozlíšiť aktivitu. WALKING znamená, že užívateľ kráča. Confidence nadobúda hodnotu 0 až 100 a vyjadruje pravdepodobnosť, že nastala daná aktivita. Informácie z tejto stránky boli síce užitočné, ale nevenujú sa kompletne všetkým položkám zo záznamu vo formáte JSON.

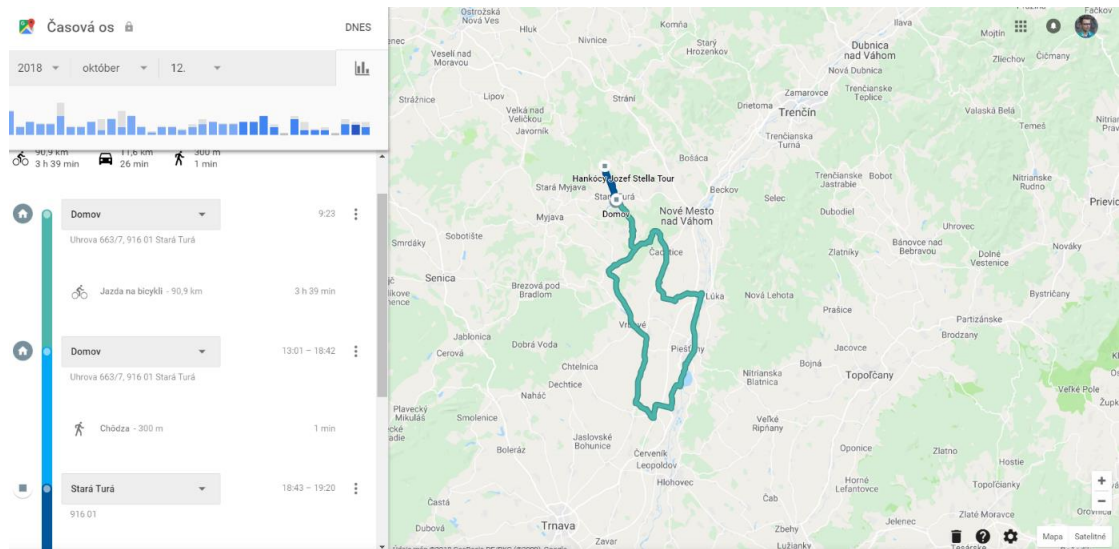
Na internetových fórach boli nájdené články ľudí, ktorí sa snažili rôznymi spôsobmi pracovať so záznamom vo formáte JSON. Mathur, 2018, sa venuje vytvoreniu osobnej heatmapy a grafov z dát z Google História polohy. Na záznam sa pozerá z programátorského pohľadu, nepracuje v geografických informačných systémoch, ale používa len skripty, pomocou ktorých pracuje so súradnicami a odstraňuje pomocou neho aj nesprávne dáta. Píše, že atribút Accuracy vyjadruje odhad, o aký presný záznam sa jedná a odstraňuje všetky záznamy s hodnotou Accuracy väčšou než 1000. Oglesby, 2018, popisuje, čo znamenajú jednotlivé položky v JSON súbore. Na konverziu dát používa BigQuery a pomocou kódu v BigQuery generuje tabuľku



Obr. 3.7 – História polohy autora práce od 2.5.2018 do 2.2.2019



Obr. 3.8 – História polohy autora práce v máji 2018



Obr 3.9 História polohy autora práce 12.10.2018

4 VLASTNÉ RIEŠENIE

Po štúdiu odbornej literatúry a spracovaní rešerše sa mohlo pristúpiť k stiahnutiu dát z Google Location a ich spracovaniu pre účely analýz priestorových vzorcov pohybu osôb.

4.1 Stiahnutie a konverzia dát

Záznam histórie polohy z Google Location bol stiahnutý vo formáte JSON (Obr. 4.1). Záznam je možné rovnako stiahnuť aj vo formáte KML. Záznam vo formáte KML sa síce dá jednoducho prekonvertovať na Feature Class (Obr. 4.2) pomocou nástroja v programe v ArcMap KML To Layer, neobsahuje však niektoré údaje, ktoré sú vo formáte JSON zahrnuté. Záznam vo formáte JSON sa nedá prekonvertovať v programe ArcGIS 10.6 pomocou nástroja JSON To Features, pretože sa nejedná o GEOJSON, rovnako neexistuje ani spôsob jeho konverzie v programe QGIS 3.2.3. Jediný spôsob zobrazenia záznamu v tomto formáte, ktorý bol nájdený, je webová aplikácia Location History Visualizer (Patt, 2019), kde je možné vizualizovať ho formou heatmapy (Obr. 4.3).


```

k
"locations" : [ {
  "timestampMs" : "1537397792411",
  "latitudeE7" : 495902829,
  "longitudeE7" : 172636926,
  "accuracy" : 1200
}, {
  "timestampMs" : "1537397671838",
  "latitudeE7" : 495902829,
  "longitudeE7" : 172636926,
  "accuracy" : 1200,
  "activity" : [ {
    "timestampMs" : "1537397615615",
    "activity" : [ {
      "type" : "ON_FOOT",
      "confidence" : 49
    }, {
      "type" : "WALKING",
      "confidence" : 49
    }, {
      "type" : "UNKNOWN",
      "confidence" : 21
    }, {
      "type" : "ON_BICYCLE",
      "confidence" : 8
    }, {
      "type" : "STILL",
      "confidence" : 7
    }, {
      "type" : "IN_VEHICLE",
      "confidence" : 5
    }, {
      "type" : "RUNNING",
      "confidence" : 5
    }, {
      "type" : "IN_ROAD_VEHICLE",
      "confidence" : 5
    }, {
      "type" : "IN_RAIL_VEHICLE",
      "confidence" : 5
    }
  ]
}
]. {
```

Obr. 4.1 Štruktúra záznamu histórie polohy vo formáte JSON

OBJECTID *	Shape *	Name	Descript	Type	Comment	Symbol	DateTime S	Elevation	DateTime
1	Point Z	1		TRKPT			2018-10-12T14:11:08Z	0	12.10.2018 14:11:08
2	Point Z	2		TRKPT			2018-10-12T13:31:05Z	0	12.10.2018 13:31:05
3	Point Z	3		TRKPT			2018-10-12T12:55:04Z	0	12.10.2018 12:55:04
4	Point Z	4		TRKPT			2018-10-12T12:19:02Z	0	12.10.2018 12:19:02
5	Point Z	5		TRKPT			2018-10-12T11:43:58Z	0	12.10.2018 11:43:58
6	Point Z	6		TRKPT			2018-10-12T11:35:11Z	0	12.10.2018 11:35:11
7	Point Z	7		TRKPT			2018-10-12T11:33:10Z	0	12.10.2018 11:33:10
8	Point Z	8		TRKPT			2018-10-12T11:31:09Z	0	12.10.2018 11:31:09
9	Point Z	9		TRKPT			2018-10-12T11:29:08Z	0	12.10.2018 11:29:08
10	Point Z	10		TRKPT			2018-10-12T11:27:07Z	0	12.10.2018 11:27:07
11	Point Z	11		TRKPT			2018-10-12T11:25:05Z	0	12.10.2018 11:25:05
12	Point Z	12		TRKPT			2018-10-12T11:23:03Z	0	12.10.2018 11:23:03
13	Point Z	13		TRKPT			2018-10-12T11:21:02Z	0	12.10.2018 11:21:02
14	Point Z	14		TRKPT			2018-10-12T11:19:01Z	0	12.10.2018 11:19:01
15	Point Z	15		TRKPT			2018-10-12T11:16:51Z	0	12.10.2018 11:16:51
16	Point Z	16		TRKPT			2018-10-12T11:14:50Z	0	12.10.2018 11:14:50
17	Point Z	17		TRKPT			2018-10-12T11:12:49Z	0	12.10.2018 11:12:49
18	Point Z	18		TRKPT			2018-10-12T11:10:48Z	0	12.10.2018 11:10:48
19	Point Z	19		TRKPT			2018-10-12T11:08:46Z	0	12.10.2018 11:08:46
20	Point Z	20		TRKPT			2018-10-12T11:06:38Z	0	12.10.2018 11:06:38
21	Point Z	21		TRKPT			2018-10-12T11:04:37Z	0	12.10.2018 11:04:37
22	Point Z	22		TRKPT			2018-10-12T10:58:33Z	0	12.10.2018 10:58:33
23	Point Z	23		TRKPT			2018-10-12T10:56:31Z	0	12.10.2018 10:56:31
24	Point Z	24		TRKPT			2018-10-12T10:54:30Z	0	12.10.2018 10:54:30
25	Point Z	25		TRKPT			2018-10-12T10:52:29Z	0	12.10.2018 10:52:29
26	Point Z	26		TRKPT			2018-10-12T10:50:27Z	0	12.10.2018 10:50:27
27	Point Z	27		TRKPT			2018-10-12T10:48:26Z	0	12.10.2018 10:48:26
28	Point Z	28		TRKPT			2018-10-12T10:46:25Z	0	12.10.2018 10:46:25
29	Point Z	29		TRKPT			2018-10-12T10:38:19Z	0	12.10.2018 10:38:19
30	Point Z	30		TRKPT			2018-10-12T10:36:16Z	0	12.10.2018 10:36:16
31	Point Z	31		TRKPT			2018-10-12T10:30:13Z	0	12.10.2018 10:30:13

Obr. 4.2 Atribútová tabuľka Histórie polohy pôvodne vo formáte KML prekonvertovanom na Feature Class



Obr. 4.3 Záznam Histórie polohy vo formáte JSON zobrazený vo forme heatmapy na stránke Location History Visualizer

Pri riešení problému z konverziou mi výrazne pomohol Mgr. Tomáš Pohanka, ktorý mi poskytol skript `read_location_data.py`, ktorý získal zo stránky Android Location Converter (Boates, 2019) a taktiež mi ukázal, ako ho spustiť pomocou príkazového riadku `OSGEO4W.bat`. Pomocou tohto skriptu je možné záznam konvertovať nielen do formátu SHP, ale aj do formátov GEOJSON a KML, záleží od toho, aká možnosť sa v príkazovom riadku zvolí. Konverziou získaný SHP súbor je v bodovej podobe a jeho Atribútová tabuľka (Obr. 4.4) obsahuje dátum (`Date`, `Date_Sub`, `Date_Str`, `DateSubStr`), čas (`Time`, `Time_Sub`), súradnice (`Longitude`, `Latitude`), odhad Googlu, o aké presné dáta sa jedná (`Accuracy`) a hodnoty pravdepodobnosti jednotlivých typov aktivít (`STILL`, `UNKNOWN`, `IN_VEHICLE`, `TILTING`, `ON_BICYCLE`, `ON_FOOT`, `WALKING`, `RUNNING`, `EXITING_VE`). Zistilo sa však, že poskytnutý skript nekonvertuje všetky položky, ktoré sa

v zázname nachádzajú. Po konverzii mal typ EXITING_VEHICLE, ktorý bol zmenený na EXITING_VE zakaždým nulovú pravdepodobnosť, hoci v zázname vo formáte JSON to nie vždy tak bolo, a okrem toho sa v pôvodnom zázname nachádzali aj typy aktivity IN FOUR WHEEL VEHICLE, IN TWO WHEEL VEHICLE, IN RAIL VEHICLE a IN ROAD VEHICLE, ktoré sa v prekonvertovanom zázname vôbec neobjavovali. Skript bol preto prepísaný tak, aby konvertoval záznam aj s týmito typmi aktivity a bol pomenovaný ako read_location_data_upgrade.py. Po konverzii sa tieto typy aktivity síce objavili v atribútovej tabuľke ako nové atribúty, avšak obsahovali len nulové hodnoty. Problém spočíval v tom, že ich názvy sú príliš dlhé a zrejme kvôli ich skráteniu zostali ich hodnoty nulové. Skript bol preto spustený znovu a namiesto formátu SHP bol zvolený formát GEOJSON. Tento formát bol následne v programe QGIS konvertovaný na formát SHP. Po tejto konverzii už záznamy novo objavených typov obsahovali hodnoty pravdepodobnosti získané z JSON súboru (Obr. 4.4).

IN RAIL VE	IN ROAD VE	IN TWO WHE	IN FOUR WH
0	0	0	0
0	0	0	0
0	0	0	0
0	0	0	0
0	0	0	0
0	0	0	0
0	0	0	0
0	0	0	0
0	0	0	0
6	6	3	3
9	8	4	4
18	8	4	4
8	5	2	2
3	4	2	2
0	0	0	0
10	6	3	3
6	6	3	3
0	0	0	0
0	51	0	51
0	100	0	100
0	100	0	100
0	0	0	0
0	0	0	0
0	0	0	0
0	0	0	0
0	0	0	0

Obr. 4.4 Hodnoty pravdepodobnosti nových aktivít v zázname prekonvertovanom do formátu GEOJSON, až potom do SHP

Dáta o histórii polohy boli poskytnuté taktiež vedúcim práce. Na ich konverziu bol použitý rovnaký postup ako pri mojich vlastných dátach. Študenti katedry geoinformatiky boli o poskytnutie dát požiadaní prostredníctvom sociálnej siete. Bolo oslovené väčšie množstvo ľudí, ale nie všetci majú históriu polohy zapnutú a nie každý bol ochotný svoj záznam poskytnúť. Bolo získaných 15 záznamov od študentov, medzi poskytovateľmi boli študenti prvého, druhého, tretieho a piateho ročníka. Všetky záznamy boli prekonvertované do formátu SHP rovnakým spôsobom ako dáta mňa a vedúceho práce. Následne boli dáta spojené do jedného súboru, z ktorého boli potom vyexportované len záznamy z katastrálneho územia mesta Olomouca z nich len dáta za časové obdobie od 1.1.2019 do 26.3.2019. Cieľom totiž bolo zvizualizovať priestorové vzory pohybu študentov katedry geoinformatiky v rámci mesta Olomouc za určité časové obdobie.

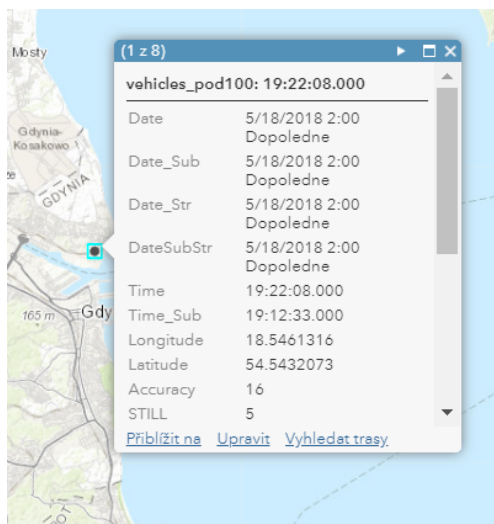
4.2 Vyhodnotenie vzniknutej bodovej vrstvy

Po úspešnej konverzii záznamu bolo potrebné zistiť, ako veľmi sa body zo záznamu aktivity zhodujú s realitou. Na toto bol použitý môj záznam, keďže som si aspoň približne pamätal, kde som sa v priebehu posledných mesiacov nachádzal a aké aktivity som tam vykonával. Export záznamov bol vykonávaný v programe ArcGIS 10.6, ale vyexportované bodové dáta bolo vždy zobrazované v ArcGIS Online z dôvodu pomalého načítania podkladových máp v programe ArcGIS 10.6.

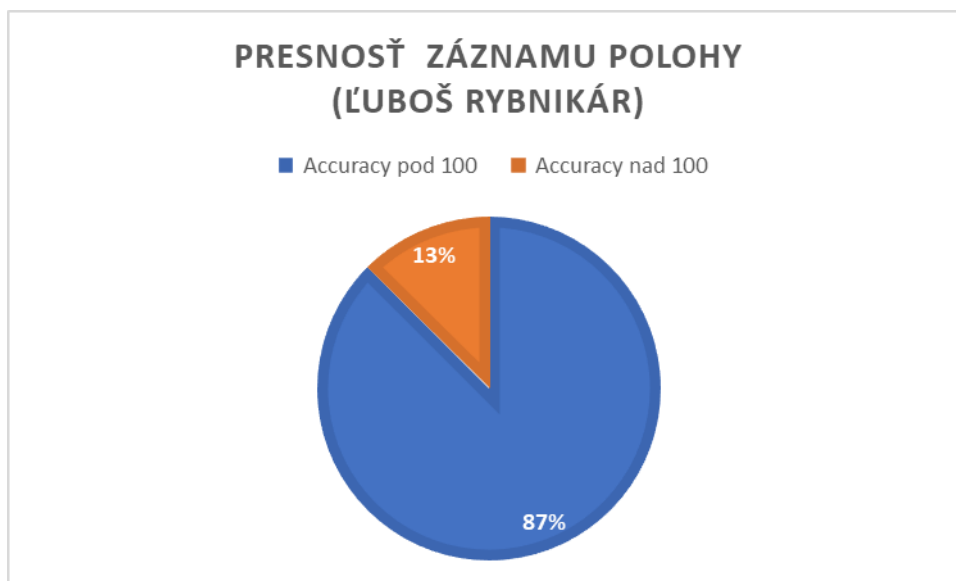
4.2.1 Odstránenie záznamov s odchýlkou

Na začiatku som si posvietil na atribút Accuracy. Zo štúdia odbornej literatúry som vedel, že atribút vyjadruje odhad Googlu, o aké presné dáta sa jedná, nebolo však jasné, v akých jednotkách je tento odhad uvedený. Aby mohli byť vykonané analýzy priestorových vzorcov pohybu osôb, nepresných záznamov sa bolo treba zbaviť

Najprv boli odstránené záznamy s hodnotou Accuracy väčšou než 1000, pretože túto hodnotu ako hraničnú použil aj Mathur, 2018. Po ich odstránení však bola ich odchýlka naďalej príliš veľká často sa objavovali body mimo budov a ciest, na ktorých som sa reálne nachádzal, preto som sa rozhodol odstrániť všetky body s Accuracy väčšou než 100. Po odstránení týchto bodov sa už v zázname nenachádzali žiadne väčšie odchýlky až na 8 bodov v meste Gdynia z 18.5.2018 (Obr. 4.5), zatiaľ čo v tom čase som sa nachádzal v meste Toruń s hodnotou Accuracy 16 a 17 a 2 body s hodnotou Accuracy 16 v meste Verona v Taliansku, zatiaľ čo v tom čase som sa nachádzal vo vlaku z Olomouca do Varšavy. Keďže však hodnoty Accuracy boli pod 100, rozhodol som sa tieto anomálie v zázname ponechať. Pomer hodnôt Accuracy nad 100 a pod 100 zobrazuje Graf 4.1.



Obr. 4.5 Chybné určenie polohy v meste Gdynia, v ktorom som nebol



Graf 4.1 – Zastúpenie bodov s veľkou odchýlkou v zázname mojej histórie polohy

4.2.2 Určenie typu aktivity

Po zbavení sa záznamov s odchýlkou bolo potrebné správne určiť typ aktivity. Najprv boli vybrané záznamy, v ktorých mali jednotlivé aktivity pravdepodobnosť 100. Typy aktivity Unknown, In Rail Vehicle, In Two Wheels Vehicle a In Four Wheels Vehicle nikdy nemali pravdepodobnosť 100.

Typy aktivity pri pravdepodobnosti 100

Záznam **Still** obsahuje body z časov, keď som aj reálne v pokoji bol. Nemuselo to vždy byť sedenie na mieste, často sa objavujú aj zastavenia pri cyklistike či chôdzi alebo státie na železničnej stanici. Nenašiel sa žiadny bod, ktorého poloha a čas by sa nemohli zhodovať s realitou.

Typ aktivity **Tilting** môže nadobúdať len hodnoty 0 alebo 100. veľkej časti záznamov, ktorej mali byť priradené iné typy aktivity bol priradený práve Tilting. Pri zmene uhlu mobilného zariadenia vzhľadom ku gravitácii zrejme Google nedokáže určiť typ aktivity, tak ju automaticky určí ako Tilting.

Typ aktivity **In Vehicle** len málokedy nadobúda pravdepodobnosť 100, ale body, ktoré túto pravdepodobnosť majú, zodpovedajú realite, objavuje sa medzi nimi jazda autobusom, autom aj lanovkou. Typ aktivity **In Road Vehicle** má pravdepodobnosť 100 vždy vtedy, keď ju má aj In Vehicle, čo už také ideálne nie je, pretože tým pádom je v ňom aj niekoľko bodov z času, keď som šiel lanovkou, ktorá cestným vozidlom nie je.

Typ aktivity **Exiting Vehicle**, ktorý nadobúda len hodnoty 0 alebo 100 pri hodnote 100 vždy zodpovedá realite. Niekedy šlo o vystupovanie z auta, inokedy z vlaku alebo z lanovky.

Typ aktivity **On Foot**, rovnako ako aj **Walking** a **Running**, ktoré podoň spadajú, vždy zodpovedajú realite a pri pravdepodobnosti 100 sa v nich nenašli žiadne chyby.

Typ aktivity **On Bicycle** zahŕňa v prevažnej miere jazdu na bicykli, ale nájdu sa v ňom aj záznamy z jazdy na lyžiach.

Typy aktivity pri pravdepodobnosti nad 50

Záznamy s pravdepodobnosťou 100 síce v pomerne veľkej miere zodpovedali realite, bolo ich však veľmi málo, preto som sa v ďalšom kroku rozhodol otestovať do akej miery zodpovedajú realite body s pravdepodobnosťou danej aktivity nad 50.

Podobne ako pri pravdepodobnosti 100, aj pri pravdepodobnosti 50 obsahuje typ aktivity **Still** záznamy z časov, keď som buď sedel na mieste alebo sa zastavil pri vykonávaní inej aktivity.

V type aktivity **In Vehicle** sa okrem záznamov z jazdy autom, vlakom či lanovkou vyskytujú občas aj záznamy z jazdy na bicykli z kopca. Typ aktivity **In Road Vehicle** už obsahuje o niečo menší počet záznamov než **In Vehicle**, ale v oboch sa vyskytujú záznamy z jazdy na bicykli z kopca. Záznamy s typom aktivity **In Rail Vehicle** nie vždy zodpovedajú jazde vlakom, vyskytuje sa v nich aj jazda inými dopravnými prostriedkami. Žiaden môj záznam nemal pravdepodobnosť aktivity **In Two Wheels Vehicle** nad 50. Typ aktivity **In Four Wheels Vehicle** nie vždy zodpovedá realite, vyskytujú sa v ňom záznamy z jazdy lanovkou, vlakom aj na bicykli z kopca.

V type aktivity **On Foot** sa pomerne často dajú nájsť aj záznamy z jazdy na bicykli do kopca. V type aktivity **Walking**, ktorý подеň spadá sa takéto záznamy tiež občas vyskytnú, rovnako ako pri type aktivity **Running**, pri ktorom je ale veľmi častá hlavne zámena s rýchlou chôdzou.

Typ aktivity **On Bicycle** sa zhoduje s realitou pomerne dobre, nájdú sa ale v ňom aj záznamy z jazdy na lyžiach.

Typ aktivity **Unknown** sa vyskytuje nepravidelne na rôznych miestach a nahrádza najčastejšie jazdu autom.

Typy aktivity pri pravdepodobnosti nad 25

Pri hraničnej pravdepodobnosti 50 už síce bolo k aktivitám pridelené väčšie množstvo dát, ale väčšine bodov nebol priradený žiaden typ aktivity, preto som ešte skúsil hraničnú hodnotu pravdepodobnosti znížiť na 25

Typ aktivity **Still** už nezodpovedá realite tak dobre, často sa vyskytuje pri jazde vlakom (nielen na železničných staniaciach) či lanovkou.

Pri type aktivity **In Vehicle** sa o niečo častejšie než predtým vyskytujú záznamy z jazdy na bicykli z kopca. Podobné je to aj pri type aktivity **In Road Vehicle**. V type aktivity **In Rail Vehicle** sa už dajú nájsť nielen záznamy z jazdy cestnými motorovými vozidlami, ale dokonca aj záznamy z jazdy na bicykli či chôdze. Objavuje sa aj 8 záznamov aktivity **In Two Wheels Vehicle** (ale na motorke som nikdy nejazdil), jedná sa o záznamy z jazdy na bicykli, autom a lanovkou. **In Four Wheels Vehicle** obsahuje okrem záznamov z jazdy štvorkolesovým vozidlom aj záznamy z jazdy lanovkou, vlakom a bicyklom (už nielen z kopca).

Pri type aktivity **On Foot** sa už veľmi často vyskytujú záznamy z jazdy na bicykli a na lyžiach a rovnako sa dokonca nájdú aj záznamy z jazdy vlakom. Záznamy z jazdy na bicykli, na lyžiach aj vlakom sa rovnako vyskytujú aj pri type aktivity **Walking**. **Running** sa veľmi často zamieňa s rýchlou chôdzou a jazdou na lyžiach.

Typ aktivity **On Bicycle** už obsahuje okrem záznamov z jazdy na lyžiach aj záznamy z chôdze a jazdy vlakom.


Unknown nahrádza rôzne typy aktivity okrem jazdy autom je už veľmi častá aj jazda bicyklom a chôdza.

Výber hraničnej hodnoty pravdepodobnosti pre ďalšiu prácu s dátami

Z porovnávania záznamov so skutočnosťou vyplýva, že ak sa určí typ aktivity tak, že sa vyberú len záznamy s pravdepodobnosťou 100, získajú sa síce dáta zodpovedajúce realite, ale je ich veľmi málo. Ak sa vyberú záznamy s pravdepodobnosťou aktivity 50, zhodnosť s realitou už nie je vždy také veľká, ale odchýlky sú zanedbateľné a dáta sú ďalej použiteľné. Ak sa vyberú záznamy s pravdepodobnosťou aktivity 25, typy aktivity

už veľmi často nezodpovedajú realite a dáta už nie sú ďalej použiteľné, aj keď je ich väčšie množstvo. Z tohto dôvodu bolo rozhodnuté, že ďalej sa bude pracovať s aktivitami s pravdepodobnosťou 50 a viac a tieto aktivity boli vybrané aj zo záznamu vedúceho práce a záznamu študentov KGI.

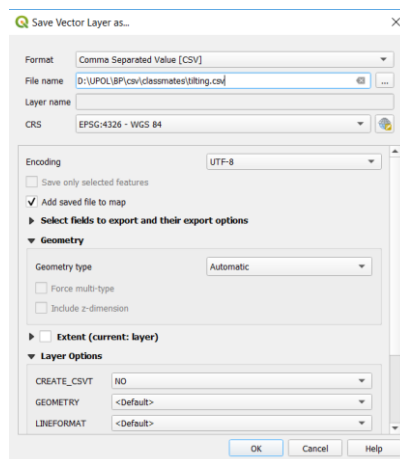
Počty bodov v mojom zázname Z Google Location s Accuracy pod 100 podľa typu aktivity a hodnoty jej pravdepodobnosti ponúka Príloha 1. Ako vidno z Grafu 4.2, pokiaľ sa určí ako hraničná pravdepodobnosť určenia typu aktivity 50, drvivá väčšina záznamov zostane bez určenia typu aktivity. Dá sa to považovať za nedokonalosť spôsobu určenia typu aktivity, ktorý som si zvolil a jeho vylepšenie môže byť témou ďalších bakalárskych či diplomových prác. Rovnaké grafy boli vytvorené aj pre dáta vedúceho práce a dáta študentov KGI (Príloha 2). Aj z týchto grafov vidno, že pri väčšine bodov nebolo možné určiť typ aktivity.



Graf 4.2 – Typy aktivity pri hraničnej hodnote pravdepodobnosti 50 v mojom zázname

4.3 Štatistická analýza dát

Po výbere záznamov vhodných na analýzy a vizualizácie nasledovala štatistická analýza. Cieľom štatistickej analýzy bolo zistiť, aký je rozptyl hodnôt pravdepodobnosti iných aktivít pri pravdepodobnosti daného typu aktivity 50 a viac. Na tento účel bola vybraná metóda boxplotov a program RStudio. Skript `boxplots_BP.R`, ktorým boli boxploty vytvorené je dostupný na priloženom DVD. Dáta boli najprv v programe QGIS 3.2.3 prekonvertované do CSV (Obr. 4.8), aby sa s nimi následne dalo v programe RStudio pracovať.



Obr. 4.8 Export formátu SHP do formátu CSV

Bolo vytvorených 14 boxplotov pre dáta vedúceho práce, 13 boxplotov pre dáta autora práce (z dôvodu absencie typu aktivity In Two Wheels Vehicle) a 14 boxplotov pre dáta študentov KGI. Typy aktivity „Unknown“, „Still“, „In Vehicle“, „On Foot“, „Walking“, „On Bicycle“ a „Running“ boli porovnávané navzájom. Typy aktivity „Tilting“ a „Exiting Vehicle“ neboli do tohto porovnávania zahrnuté, boli pre ne vytvorené len boxploty dokazujúce, že pokiaľ majú hodnotu 100, všetky iné aktivity majú nulovú hodnotu. Typy aktivity „In Road Vehicle“, „In Rail Vehicle“, „In Two Wheels Vehicle“ a „In Four Wheels Vehicle“ boli porovnávané len s typom aktivity In Vehicle, pod ktorý spadajú a nie s ostatnými typmi aktivity, pretože takéto porovnávanie by bolo zbytočné. Interpretácii boxplotov sa venuje kapitola výsledky práce. Voxploty sú v dokumente dostupné ako Príloha 4.

4.4 Kartografická vizualizácia dát

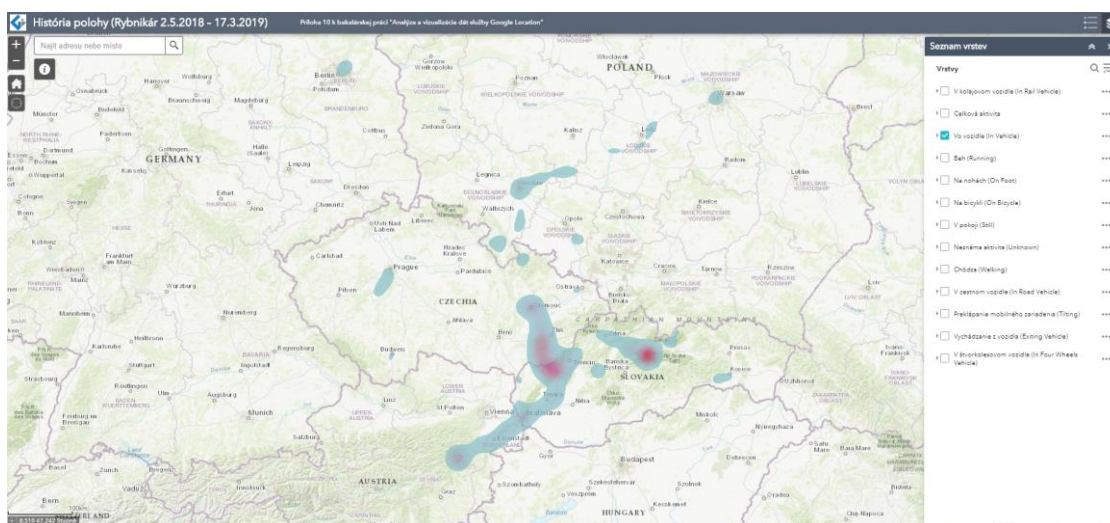
Pôvodným zámerom bolo vytvorenie líniových trás pre jednotlivé typy aktivity pomocou nástroja Points To Line v programe ArcGIS 10.6. Od toho zámeru som však musel upustiť kvôli tomu, že väčšine bodov nebol priradený žiaden typ aktivity. Dáta boli nakoniec zvizualizované troma spôsobmi, a to prostredníctvom piatich webových mapových aplikácií vytvorených prostredníctvom WebAppBuilderu v ArcGIS Online (Príloha 8-12), osemnástich heatmáp vytvorených v programe ArcGIS 10.6 (Príloha 13-30) a pätnástich máp trajektórií pohybu vytvorených v programe V-Analytics (Príloha5).

4.4.1 Webové mapové aplikácie

Prvým spôsobom vizualizácie boli webové mapové aplikácie publikované pomocou nástroja WebAppBuilder v ArcGIS Online. Prvým krokom bolo nahranie bodových dát do ArcGIS Online. Dáta boli publikované prostredníctvom programu ArcGIS 10.6. V ArcGIS Online boli vytvorené heatmapy pre všetky typy aktivít, mňa, vedúceho práce a študentov KGI. Nevýhodou tvorby heatmáp v ArcGIS Online je, že výber stupnic nie je taký široký ako v programe ArcGIS 10.6 a nie je ani možné nahráť svoju vlastnú stupnicu. Uvedomujem si, že na zobrazenie intenzity aktivity by sa viac hodila konvergentná stupnica, ale z palety ponúkaných stupnic sa stupnica vybraná pre účely vizualizácie javila ako najlepšia. Záznamy pre jednotlivé aktivity obsahovali rôzne množstvá bodov a preto môžu vizualizácie pomocou rovnakých stupnic pôsobiť zavádzajúco. Jednoznačnou výhodou je podkladová mapa, ktorá sa nenačíta tak dlho

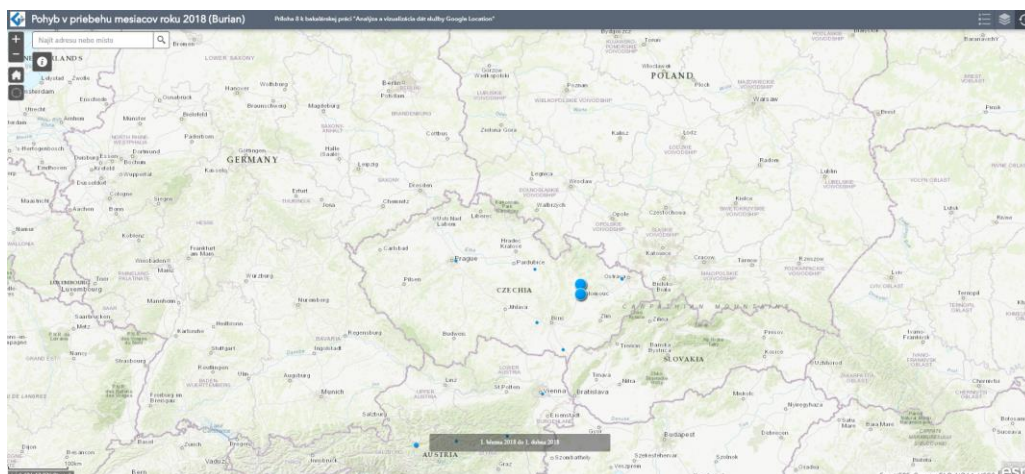
ako programe ArcGIS, jednoduché približovanie a odďaľovanie a taktiež to, že užívateľ webovej aplikácie sa sám môže rozhodnúť, ktoré heatmapy si chce zobraziť.

V aplikácii s heatmapami aktivít autora práce (Obr. 4.9, Príloha 10) je dostupná jednak celková vizualizácia záznamov histórie polohy s Accuracy pod 100, zahŕňajúca teda aj bodové záznamy, v ktorých sa nepodarilo určiť typ aktivity (položka „Celková aktivita“ a súčasne všetky typy aktivity s výnimkou typu In Two Wheels Vehicle, pre ktorý žiaden môj záznam nemal pravdepodobnosť nad 50. Zvizualizované sú dáta pre všetky štáty, ktoré som v priebehu zaznamenávania histórie polohy navštívil. Úplne rovnaký spôsob je použitý aj v aplikácii zobrazujúcej históriu polohy RNDr. Jaroslava Buriana, PhD. (Príloha 11). Aj v jeho prípade chýba vizualizácia typu aktivity In Two Wheels Vehicle, pretože ten obsahoval len dva bodové záznamy. Celková aktivita a typy aktivity študentov katedry geoinformatiky s výnimkou typu In Two Wheels Vehicle, ktorý sa aj v ich prípade vyskytoval len dvakrát, je vizualizovaná vo webovej aplikácii (Príloha 12) len v rámci územia mesta Olomouc.



Obr. 4.9 Webová mapa aktivít autora práce

Okrem toho boli vytvorené aj dve webové mapové aplikácie zobrazujúce históriu polohy v priebehu dvanástich mesiacov. Poloha v tomto prípade nie je vizualizovaná formou heatmapy, ale formou agregovaných bodových znakov. V prípade dát vedúceho práce je vizualizovaná história polohy v priebehu mesiacov roku 2018 (Príloha 8, Obr. 4.10). V prípade mojich dát je vizualizovaná história polohy od mája 2018 do apríla 2019 (Príloha 9). Pre účely tejto vizualizácie bol 25.4.2019 stiahnutý nový záznam histórie polohy.



Obr. 4.10 Webová animácia celkovej aktivity vedúceho práce

4.4.2 Analógové mapy

Celkove bolo vytvorených 18 tematických analógových máp zobrazujúcich aktivitu metódou heatmapy. Je v nich vyjadrená celková aktivita a typy aktivity In Vehicle, On Bicycle, Running, Still a Walking. Aktivity autora práce je vizualizovaná na Slovensku, v Česku a v Poľsku, pretože v týchto krajinách sa autor pohyboval väčšinu času v priebehu zberu dát. Aktivity autora práce sú vizualizované pre územie Českej republiky, pretože v tejto krajine sa pohyboval väčšinu času v priebehu zberu dát. Aktivity študentov KGI sú vizualizované pre územie mesta Olomouc, pretože sa pracovalo len s dátami študentov KGI pre mesto Olomouc.

Heatmapy, ktoré tvoria základ analógových máp, boli vytvorené pomocou nástroja Kernel Density. Hodnota veľkosti bunky bola vždy nastavená na 0,01. Vzniknutý rastrový súbor bol vždy následne upravený pomocou nástroja Reclassify, aby sa z neho odstránili hodnoty od 0 do 1. Pre rovnaké typy aktivity bola vždy v mapách zvolená rovnaká stupnica a podľa farby stupnice bola zvolená aj farba nadpisu a rámu. V mapách mojej aktivity boli ako topografický podklad zvolené hranice štátov a krajské mestá, v prípade Poľska sídla vojvodstiev. V mapách aktivity vedúceho práce boli ako topografický podklad zvolené hranice krajov, krajské mestá a tieňovaný reliéf. V mapách aktivity študentov KGI boli topografickým podkladom železnice, cesty a tieňovaný reliéf.

4.4.3 Vizualizácie trajektórií vo V-Analytics

Posledným spôsobom vizualizácie dát boli vizualizácie trajektórií pohybu v rámci Olomouca v programe V-Analytics. Bolo vytvorených spolu 15 máp, ktoré zahŕňali mapy trajektórií celkovej aktivity a aktivít In Vehicle, On Bicycle, Running a Walking z dát autora práce, vedúceho práce a študentov KGI.

Nahrávanie dát do programu je veľmi komplikované a výraznú pomoc mi pri ňom poskytol RNDr. Stanislav Popelka, Ph.D., ktorý ma súčasne oboznámil aj s fungovaním celého programu. Najprv boli záznamy aktivity z Olomouca v programe QGIS 3.2.3 prekonvertované do formátu CSV. Záznam vo formáte CSV musí byť upravený, je do neho potrebné pridať stĺpce pIDx (index bodu v línii) a trN (číslo trajektórie) a formát dátumu bol zmenený na yyyy-mm-dd (Obr. 4.11). Práca s programom je veľmi komplikovaná a neprišiel som na spôsob, ako v priamo v programe vytvoriť

5 VÝSLEDKY

Nasledujúca kapitola zhrňa výsledky, ktoré boli v práci dosiahnuté a snaží sa o ich interpretáciu. Za prvý výsledok práce sa dá považovať prepísaný skript v pythone (read_location_data_upgrade.py), ktorý na rozdiel od pôvodného skriptu konvertuje 4 nové typov aktivity, ktoré ten starý nekonvertoval. Výsledkami štatistických analýz sú tabuľka, grafy a boxploty. Hlavnými výsledkami práce sú mapové výstupy a ich interpretácie. Celkove bolo vytvorených 5 webových mapových aplikácií, 18 analógových máp a 15 digitálnych máp.

5.1 Výsledky štatistických analýz a ich interpretácia

5.1.1 Presnosť dát služby Google Location

V programe MS Excel 2016 boli vytvorené grafy predstavujúce percentuálny pomer bodových záznamov aktivity s hodnotou atribútu Accuracy nad 100 a pod 100 v dátach autora práce, vedúceho práce a študentov katedry geoinformatiky v rámci mesta Olomouc (Príloha 2). Najväčšiu presnosť má záznam aktivity študentov Katedry geoinformatiky v rámci mesta Olomouc, kde má až 97% bodových záznamov hodnotu Accuracy pod 100. Je to možno aj tým, že pri dátach 15 študentov KGI sa pracovalo len s dátami pre mesto Olomouc a keby sa pracovalo s úplne všetkými záznamami, presnosť by asi nebola až taká vysoká. V dátach autora práce má 87% bodových záznamov Accuracy pod 100 a v dátach vedúceho práce 83%. Počet presných bodových záznamov sa ale dá vo všetkých troch prípadoch považovať za vysoký.

Bola vytvorená tabuľka predstavujúca počty a percentuálne zastúpenie bodov v zázname autora z Google Location s Accuracy pod 100, ktorým boli priradené jednotlivé typy aktivity pri hodnotách pravdepodobnosti 100, 50 a viac a 25 a viac (Príloha 1). Tabuľka bola vytvorená v čase, keď sa rozhodovalo, aká hodnota pravdepodobnosti bude hraničná pri určení typu aktivity. Z tabuľky veľmi dobre vidieť, že väčšine bodových záznamov sa ani pri znižovaní hraničnej pravdepodobnosti aktivity nepodarilo priradiť typ aktivity. Boli taktiež vytvorené grafy vyjadrujúce počty záznamov jednotlivých typov aktivity pri hraničnej pravdepodobnosti aktivity 50, ktorá bola nakoniec zvolená ako najvhodnejšia hraničná pravdepodobnosť typu aktivity (Príloha 3).

5.1.2 Rozptyl hodnôt pravdepodobnosti dát služby Google Location

V programe RStudio bolo vytvorených spolu 41 boxplotov vyjadrujúcich rozptyl hodnôt iných typov aktivity pri konkrétnom type aktivity. Bolo vytvorených 14 boxplotov pre dáta vedúceho práce, 13 boxplotov pre dáta autora práce (z dôvodu absencie typu aktivity In Two Wheels Vehicle) a 14 boxplotov pre dáta študentov KGI. Typy aktivity „Unknown“, „Still“, „In Vehicle“, „On Foot“, „Walking“, „On Bicycle“ a „Running“ boli porovnávané navzájom. Typy aktivity „Tilting“ a „Exiting Vehicle“ neboli do tohto porovňávania zahrnuté, boli pre ne vytvorené len boxploty dokazujúce, že pokiaľ majú hodnotu 100, teda jedinú hodnotu, ktorú okrem nuly môžu nadobudnúť, všetky iné aktivity majú nulovú hodnotu. Typy aktivity „In Road Vehicle“, „In Rail Vehicle“, „In Two Wheels Vehicle“ a „In Four Wheels Vehicle“ boli porovnávané len s typom aktivity In Vehicle, pod ktorý spadajú a nie s ostatnými typmi aktivity, pretože takéto porovnávanie

by bolo zbytočné. Všetky boxploty sa dajú nájsť v Prilohe 4, vybrané boxploty sú umiestnené aj priamo do textu.

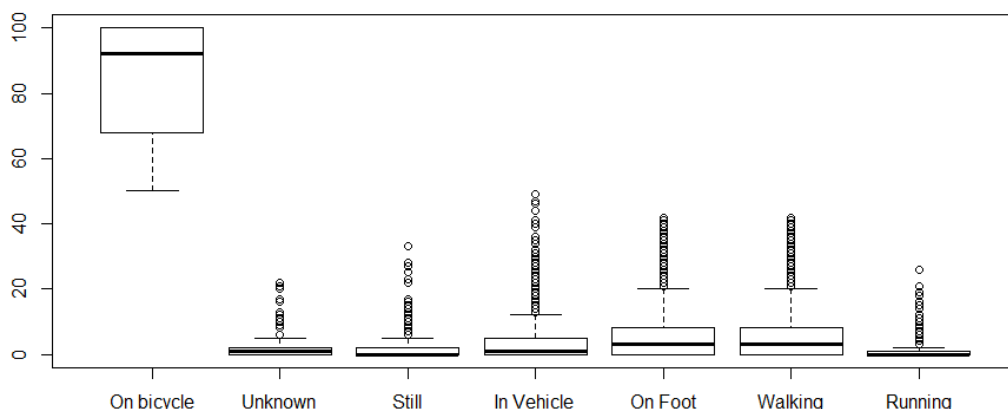
Istoty aktivít pri istote „In Vehicle“ nad 50

Ako môžeme vidieť z boxplotu vyjadrujúceho pravdepodobnosť iných aktivít pri pravdepodobnosti aktivity „In Vehicle“ nad 50 v mojich dátach, niektoré bodové záznamy aktivity „In Vehicle“ majú pravdepodobnosť aktivity „Unknown“ vyššiu než 50. k tejto hodnote sa približujú aj outliery pravdepodobností aktivít Still, On Bicycle, On Foot a Walking. V prípade boxplotu pre tento typ aktivity u vedúceho práce je počet outlierov aktivity Unknown vyšší a súčasne sa v početnej miere objavujú aj outliery aktivity Still. Mohlo by to napríklad znamenať, že pri jazde automobilom sa zastavil na benzínovej pumpe, prípade pri jazde vlakom na železničnej stanici. V prípade dát študentov KGI outliery pravdepodobnosti žiadneho typu aktivity neprekračujú hodnotu 50 ani sa k nej nepribližujú.

Istoty aktivít pri istote „On Bicycle“ nad 50

Ako môžeme vidieť z boxplotu vyjadrujúceho pravdepodobnosť iných aktivít pri pravdepodobnosti aktivity „On Bicycle“ nad 50 v dátach autora práce (Graf 5.1), žiadna iná aktivita sa neprekrýva s aktivitou „On Bicycle“, aj keď niektoré outliery pravdepodobnosti aktivít „In Vehicle“, „On Foot“ a „Walking“ sa k tejto hodnote výrazne približujú. V rovnakom boxplote pre dáta vedúceho práce je situácia podobná, ale v boxplote pre dáta študentov KGI sa outliery k hodnote 50 približujú výrazne menej.

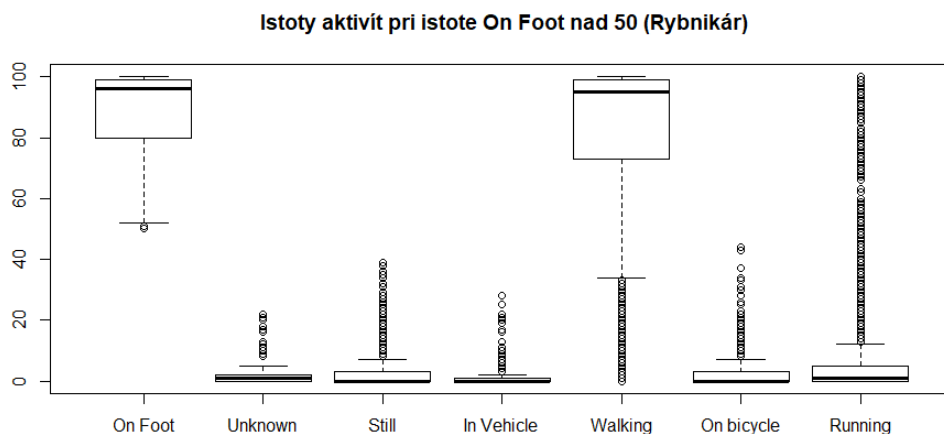
Istoty aktivít pri istote On Bicycle nad 50 (Rybnikár)



Graf 5.1 Istoty aktivít pri istote aktivity „On Bicycle“ nad 50

Istoty aktivít pri istote „On Foot“ nad 50

Z boxplotov vyjadrujúceho pravdepodobnosť iných aktivít pri pravdepodobnosti „On Foot“ nad 50 môžeme pekne vidieť, že typy aktivity „Running“ a „Walking“ spadajú pod „On Foot“. V prípade dát autora (Graf 5.2) a študentov KGI sa k hodnote 50 približujú rezíduá pravdepodobnosti aktivít Still a On Bicycle, v prípade vedúceho práce aj Unknown a In Vehicle.



Graf 5.2 Istoty aktivít pri istote aktivít „On Foot“ nad 50

Istoty aktivít pri istote „Running“ nad 50


V boxplotoch vyjadrujúcej pravdepodobnosť iných aktivít pri pravdepodobnosti aktivít „Running“ nad 50 znovu pekne vidieť, že typ aktivít „Running“ spadá pod typ aktivít „On Foot“. V prípade dát autora a študentov KGI sa k hodnote 50 približujú inak len hodnoty pravdepodobnosti aktivít „Walking“, v prípade dát vedúceho práce aj outliers pravdepodobností aktivít „Unknown“, „In Vehicle“ a „On Bicycle“.

Istoty aktivít pri istote „Still“ nad 50

V boxplotoch vyjadrujúcej pravdepodobnosť iných aktivít pri pravdepodobnosti aktivít „Still“ nad 50 v záznamoch autora práce a študentov KGI sa outliers pravdepodobnosti aktivít In Vehicle, On Foot, Walking a On Bicycle blížia k hodnote 50. V zázname vedúceho práce niektoré hodnoty pravdepodobnosti typov aktivít „Unknown“ a „In Vehicle“ prekračujú hodnotu 50.

Istoty aktivít pri istote „Exiting Vehicle“ a „Tilting“ nad 50

V boxplotoch vyjadrujúcej pravdepodobnosť iných aktivít pri pravdepodobnosti aktivít „Exiting Vehicle“ nad 50 (Graf 5.3) a „Tilting“ nad 50 môžeme vidieť, že tieto 2 aktivity nadobúdajú len hodnotu pravdepodobnosti 100 a všetky iné typy aktivít majú v takom prípade pravdepodobnosť 0. Ako píše Google Developers, 2019, typ aktivít je určený ako „Tilting“ vtedy, keď sa uhol zariadenia vzhľadom ku gravitácii výrazne zmení, ale nepodarilo sa zistiť, podľa čoho sa určuje typ aktivít „Exiting Vehicle“.



Graf 5.3 Istoty aktivít pri istote aktivít „Exiting Vehicle“ nad 50

Istoty aktivít pri istote „Unknown“ nad 50

V boxplotoch vyjadrujúcej pravdepodobnosť iných aktivít pri pravdepodobnosti aktivity „Unknown“ nad 50 v prípade mojich dát vidíme, že hodnoty pravdepodobnosti tohto typu aktivity sa prekrývajú s hodnotami pravdepodobnosti aktivity „In Vehicle“. V dátach vedúceho práce je pozorovaný aj čiastočný prekryv s hodnotami pravdepodobnosti aktivity „Still“. V dátach študentov KGI sa dá pozorovať zaujímavá vec, a to že hodnoty pravdepodobnosti typu aktivity „Unknown“ nepresahujú hodnotu 50. Pre kontrolu tohto na prvý pohľad podozrivého javu bola skontrolovaná atribútová tabuľka záznamu, kde sa overilo, že typ aktivity väčšiu hodnotu pravdepodobnosti nedosahuje. Spôsobené je to zrejme tým, že v prípade študentov KGI sa spracovávali len ich dáta za mesto Olomouc, kde je pomerne dobrý mobilný signál.


Istoty aktivít pri istote „Walking“ nad 50

V boxplotoch vyjadrujúcej pravdepodobnosť iných aktivít pri pravdepodobnosti aktivity „Walking“ nad 50 znovu pekne vidíme, že typ aktivity „Walking“ spadá pod typ aktivity „On Foot“. V dátach autora práce, vedúceho práce a študentov KGI vidíme, že k číslu 50 sa najviac približujú reziduálne hodnoty pravdepodobnosti aktivít „Still“ a „On Bicycle“.

Istoty typov dopravných prostriedkov pri istote „In Vehicle“ nad 50

Záznam histórie polohy zahŕňa aj pravdepodobnosti jazdy štyrmi typmi dopravných prostriedkov – „In Two Wheels Vehicle“, „In Four Wheels Vehicle“, „In Rail Vehicle“ a „In Rail Vehicle“. Tieto typy aktivity boli formou boxplotov porovnávané navzájom a s typom aktivity „In Vehicle“.

V boxplotoch porovnávajúcich pravdepodobnosť jednotlivých typov dopravných prostriedkov s pravdepodobnosťou aktivity „In Vehicle“ (Graf 5.4) môžeme vidieť, že veľká časť záznamov má súčasne vysokú pravdepodobnosť aktivity „In Road Vehicle“ a o niečo menšia časť má tiež vysoké hodnoty pravdepodobnosti aktivity „In Four Wheels Vehicle“. Len malá časť záznamov má hodnoty pravdepodobnosti aktivity „In Rail Vehicle“ nad 50. 2 hodnoty pravdepodobnosti aktivity „In Two Wheels Vehicle“ nad 50 sa vyskytujú v záznamoch vedúceho práce a študentov KGI a v dátach autora práce sa nenachádza žiaden záznam, ktorý by mal hodnotu pravdepodobnosti tejto aktivity nad 50.



Graf 5.4 Istoty typov dopravných prostriedkov pri istote aktivity „In Vehicle“ nad 50

Istoty typov dopravných prostriedkov pri istote „In Two Wheels Vehicle“ nad 50

V boxplotoch porovnávajúcich pravdepodobnosť jednotlivých typov dopravných prostriedkov s pravdepodobnosťou aktivity „In Two Wheels Vehicle“ nad 50 môžeme vidieť, že pri tomto type aktivity sú vysoké hodnoty pravdepodobnosti aktivít „In Vehicle“ a „In Road Vehicle“ a pravdepodobnosti aktivít „In Four Wheels Vehicle“ a „In Rail Vehicle“ sú nízke, až nulové.

Istoty typov dopravných prostriedkov pri istote „In Four Wheels Vehicle“ nad 50

V boxplotoch porovnávajúcich pravdepodobnosť jednotlivých typov dopravných prostriedkov s pravdepodobnosťou aktivity „In Four Wheels Vehicle“ nad 50 vidieť, že hodnoty pravdepodobností aktivít „In Vehicle“ a „In Road Vehicle“ sa pohybujú približne v podobnom rozpätí a hodnoty pravdepodobností aktivít „In Rail Vehicle“ a „In Two Wheels Vehicle“ sú nízke, čo je celkom logické a neprekvapivé.

Istoty typov dopravných prostriedkov pri istote „In Road Vehicle“ nad 50

V boxplotoch porovnávajúcich pravdepodobnosť jednotlivých typov dopravných prostriedkov s pravdepodobnosťou aktivity „In Road Vehicle“ nad 50 vidieť, že hodnoty pravdepodobnosti aktivity „In Vehicle“ sa pohybujú v úplne rovnakom rozpätí. Pravdepodobnosť aktivity „In Four Wheels Vehicle“ sa pohybuje v rozmedzí od 0 do 100, v dátach vedúceho práce je však medián blízko nule, zatiaľ čo v dátach autora práce študentov KGI sa nachádza na hodnotách 60 a 80. Pravdepodobnosť aktivity „In Rail Vehicle“ je vždy nižšia než 50 a len malá časť záznamov aktivity „In Two Wheels Vehicle“ má hodnotu pravdepodobnosti vyššiu než 50, v dátach autora práce ju nemajú žiadne záznamy.

Istoty typov dopravných prostriedkov pri istote „In Rail Vehicle“ nad 50

V boxplotoch porovnávajúcich pravdepodobnosť jednotlivých typov dopravných prostriedkov s pravdepodobnosťou aktivity „In Road Vehicle“ nad 50 vidíme, že rozptyl jeho hodnôt je takmer zhodný s rozptylom hodnôt aktivity „In Vehicle“. Pravdepodobnosti jazdy inými dopravnými prostriedkami neprekračujú hodnotu 50, najbližšie k nej sa pohybujú pravdepodobnosti aktivity „In Road Vehicle“

5.2 Výsledky kartografických vizualizácií a ich interpretácia

Boli vytvorené 3 typy kartografických výstupov a to webové mapové aplikácie vytvorené v ArcGIS Online, papierové tlačené mapy vytvorené v programe ArcGIS 10.6 a mapy trajektórií aktivít v Olomouci vytvorené v softvéri V-Analytics.

5.2.1 Popis výsledkov

Bolo vytvorených spolu **5 webových mapových aplikácií**. Aplikácie boli vytvorené v ArcGIS Online pomocou nástroja WebApp Builder. Podrobnejší postup pri tvorbe aplikácií je popísaný v kapitolách 3 a 4. Prvé dve aplikácie sú animáciami, v ktorých je vizualizovaná celková aktivita autora a vedúceho práce v priebehu dvanástich mesiacov. Zo záznamu aktivity vedúceho práce boli vybrané údaje za rok 2018 a bola z nich vytvorená vizualizácia jeho pohybu v priebehu tohto roku (Príloha 8) Aby bolo možné vytvoriť vizualizáciu pohybu autora v priebehu dvanástich mesiacov, musel byť stiahnutý nový záznam z Google Location, ktorý zahrňal aj údaje o pohybe za mesiac

apríl. Bola vytvorená vizualizácia jeho pohybu od mája 2018, keď si aktivoval zaznamenávanie polohy, do apríla 2019. (Príloha 9).

V ďalších troch aplikáciách je vizualizovaná celková aktivita a všetky typy aktivity autora práce (Príloha 10), vedúceho práce (Príloha 11) a študentov KGI (Príloha 12) formou heatmáp. Nebolo prístupné jedine k vizualizácii typu aktivity „In Two Wheels Vehicle“, pretože ten v prípade autora práce neobsahuje žiadne záznamy a v prípade vedúceho práce a študentov KGI obsahuje po 2 záznamy.

Analógové mapy boli vytvorené v programe ArcGIS 10.6 vytvorením heatmáp z bodových dát pomocou nástroja Kernel Density. Boli vytvorené heatmapy celkovej histórie polohy a následne heatmapy vybraných aktivít. Na rozdiel od webových mapových aplikácií neboli vytvorené mapy pre všetky typy aktivity, ale len heatmapy pre aktivity „In Vehicle“, „On Bicycle“, „Running“, „Still“ a „Walking“. Na vizualizáciu aktivity autora práce boli vytvorené heatmapy jeho vybraných aktivít V Česku, na Slovensku a v Poľsku, teda v štátoch, v ktorých sa počas zaznamenávania histórie polohy najviac pohyboval. Analógové mapy vybraných typov aktivity vedúceho práce boli vytvorené pre územie Českej republiky, pretože na území tohto štátu sa vedúci práce najviac vyskytoval. Analógové mapy aktivity študentov KGI boli vytvorené pre dáta z územia mesta Olomouc, pretože v prípade študentov KGI boli aj celkove skúmané len ich dáta za mesto Olomouc.

Mapy trajektórií aktivít autora práce, vedúceho práce a študentov KGI v Olomouci boli vytvorené v softvéri V-Analytics (Príloha 5). Práca pri ich tvorbe je podrobnejšie popísaná v kapitole 4. Podobne ako v predchádzajúcom prípade bola zmapovaná celková aktivita a aktivity „In Vehicle“, „On Bicycle“, „Running“ a „Walking“. Trajektórie aktivity „Still“ neboli zmapované, pretože mapovať „pohyb v pokoji“ by bol nezmysel.

5.2.2 Interpretácia výsledkov

Pohyb v priebehu mesiacov roku 2018 (Burian)

Z webovej mapovej aplikácie zobrazujúcej pohyb vedúceho práce v priebehu mesiacov roku môžeme vidieť, že v **januári** sa vedúci práce pohyboval hlavne v Olomouci a v Rakúskych Alpách. Vo **februári** bol len v Českej republike, hlavne v Olomouci, ale aj v Prahe a v Jeseníkoch. V **marci** sa zdržiaval hlavne v Olomouci, ale bol aj v rakúskych Alpách a v slovinskom Maribore. V **apríli** bol opäť len v Českej republike. Najviac bol v Olomouci podnikal aj výlety do hôr v jeho okolí. V **máji** bol tiež len v Českej republike, opäť najviac v Olomouci a jeho okolí. Okrem toho podnikol klasickú cestu do Prahy a výlety do Hostýnsko-Vsetínskej hornatiny, Žďárskych vrchov a navštívil Vysokú školu báňsku v Ostrave. V **júni** bol v Česku a na Slovensku. Okrem Olomouca sa pohyboval v Žďárskych vrchoch a Jeseníkoch a na Slovensku navštívil Tatry, konkrétne okolie Štrbského plesa. V **júli** strávil väčšinu času v Tatrách, kde podnikol niekoľko turistík a ubytovaný bol v blízkosti Štrbského plesa. Okrem Tatier bol v Olomouci, v Eberswalde pri Berlíne, v Triglavskom národnom parku a v Chorvátsku v okolí Zadaru. V **auguste** strávil najviac času v Olomouci, ale bol aj na chorvátskom ostrove Rab. V **septembri** strávil väčšinu času v Olomouci, ale zavítal aj do Zlatých Hôr a do Viedne. V **októbri** najviac času strávil v Olomouci, ale bol aj v Tatrách, Jeseníkoch, Prahe, Náměšti nad Oslavou a podľa všetkého zavítal aj na Lysú Horu. V **novembri** k jeho najvýznamnejším lokalitám opäť patrili Olomouc, Tatry a Jeseníky, ale navštívil aj slovinský Maribor. V **decembri** bol najmä v Olomouci, ale navštívil aj Prahu a Náměšť nad Oslavou.

Popis bol zostavený autorom práce bez predchádzajúcej konzultácie s jej vedúcim. Po jeho napísaní vedúci potvrdil jeho správnosť.

Pohyb od mája 2018 do apríla 2019 (Rybnikár)

Ako môžeme vidieť z vizualizácie pohybu autora práce od mája 2018 do apríla 2019, v **máji 2018** strávil autor práce najviac času v meste Vroclav, ale navštívil aj pohorie Góry Bystrzyckie a mestá Stará Turá, Olomouc, Wałbrzych, Toruń, Štetín a Berlín. Objavuje sa aj agregovaný bod v meste Gdynia, čo je však chyba, pretože ho nenavštívil. V **júni 2018** sa opäť najviac zdržiaval v meste Vroclav, nejaký čas pobudol v Olomouci a Starej Turej a navštívil aj mestá Varšava a Katovice. Prevažnú časť **júla 2018** strávil v Starej Turej a okolí, ale navštívil aj ostrov Sardínia a mestá Olomouc a Bratislava. V **auguste 2018** bol hlavne v Starej Turej, no navštívil aj Tatry, Český Krumlov, Košice, Slovenský Kras a Prahu. V **septembri 2018** dominujú v jeho aktivite Stará Turá, Olomouc a ich okolie, ale bol aj v Košiciach. V **októbri 2018** sa pod vplyvom školských povinností už začal koncentrovať viac v Olomouci než v Starej Turej a navštívil aj Jeseníky a Vroclav. V **novembri 2018** v jeho zázname dominujú Olomouc a Vilnius a pekne tiež vidieť trasu medzi týmito mestami. V **decembri 2018** strávil v Starej Turej viac času než v Olomouci a navštívil aj Bratislavu. V **januári 2019** najviac času strávil v Starej Turej, ale bol aj v Olomouci, v nemeckom meste Marburg a v lyžiarskom stredisku Malinô Brdo. Vo **februári 2019** strávil najviac času v Olomouci, ale bol aj v Starej Turej a v lyžiarskom stredisku Jasná. V **marci 2019** sa najviac zdržiaval v Olomouci a Starej Turej, ale navštívil aj Vršatské bradlá a rakúsky Semmering. V **apríli 2019** najviac času strávil v Olomouci, ale bol aj v Starej Turej a v Gdaňsku.

Ako autor môžem potvrdiť, že záznamy mojej aktivity sa pomerne dobre zhodujú s realitou, s výnimkou nepochopiteľnej odchýlky v meste Gdynia v máji 2018. Z dát pre november sa zdá, že viac času som strávil v meste Vilnius než v Olomouci, to je však spôsobené tým, že v tomto mesiaci som nejaký čas používal iný mobilný telefón, na ktorom nebolo možné zaznamenávať históriu polohy.

Vizualizácie jednotlivých typov aktivity (Rybnikár 2.5.2018 – 17.3.2019)

Z heatmapy **celkovej aktivity autora** vidieť, že v priebehu zaznamenávania polohy **sa najviac zdržiaval v okolí Olomouca a Starej Turej**. Medzi ďalšie jeho významné lokality patrí sever ostrova **Sardínia, Vroclav, Vilnius a Marburg**. Z mapy intenzity jeho celkovej aktivity na Slovensku, v Česku a v Poľsku (Príloha 13) vidieť, že autor strávil najviac času v Starej Turej, ktoré je miestom jeho trvalého bydliska, v Olomouci, kde študuje a vo Vroclave, kde bol na výmennom pobyte. Z mapy trajektórií záznamov celkovej aktivity autora práce **v Olomouci** vidno, že **najčastejšie sa presúval z centrálnej časti mesta na železničnú stanicu**.

Z heatmapy aktivity **V Pokoji** (Still) vidieť, že najviac času bez pohybu na jednom mieste strávil v mestách **Olomouc, Stará Turá a Vroclav**. Rovnakú vec je možné pozorovať aj z mapy intenzity jeho aktivity „Still“ na Slovensku, v Česku a v Poľsku (Príloha 14).

Z heatmapy aktivity **Vo vozidle** (In Vehicle) sa dá vyčítať, že jeho najfrekventovanejšou trasou je **trasa medzi mestami Stará Turá a Olomouc** a veľa času vo vozidle strávil aj v lyžiarskom stredisku Jasná v Nízkych Tatrách. Rovnako je to možné pozorovať aj z mapy intenzity jeho aktivity „In Vehicle“ na Slovensku, v Česku a v Poľsku (Príloha 15). Mapa trajektórií záznamov aktivity „In Vehicle“ v Olomouci je zvláštna a zdá sa z nej, že autor sa najčastejšie dopravným prostriedkom pohyboval na

opačnej strane rieky Moravy, než je areál Envelopa a od nákupného centra Šantovka smerom do centra mesta.

V heatmape aktivity **V cestnom vozidle** (In Road Vehicle) znova pekne vidieť **trasu medzi Starou Turou a Olomoucom** a taktiež vidieť to, ako je jazda lanovkou chybné určená ako jazda cestným vozidlom. V heatmape aktivity **V koľajovom vozidle** (In Rail Vehicle) sa ako najfrekventovanejšia javí **trasa z Nového mesta nad Váhom do Uherského Hradišťa**, o niečo menej frekventovaná je potom ďalej do Olomouca. V heatmape aktivity **v štvorkolesovom vozidle** (In Four Wheels Vehicle) je oblasťou s najväčšou intenzitou **lyžiarske stredisko Jasná**, čo je nezmysel.

Najväčšia intenzita aktivity **Vychádzanie z vozidla** (Exiting Vehicle) je podľa heatmapy **v lyžiarskom stredisku Jasná**, čo je vzhľadom k častému vychádzaniu z lanovky pravdou. Veľmi zaujímavé je, že veľká intenzita sa dá pozorovať aj **v mestách Velká nad Veličkou, Veselí nad Moravou a Uherské Hradiště**, v ktorých autor prestupuje, keď cestuje vlakom z miesta bydliska do Olomouca.

Z heatmapy aktivity **Na bicykli** (On Bicycle) vidieť, že autor sa bicykluje najviac **v okolí Starej Turej a Olomouca**. Zobrazuje sa aj početná aktivita v lyžiarskych strediskách, tu bol však typ aktivity zamenený s lyžovaním. Problémom možno je, že záznam histórie polohy neobsahuje typ aktivity Skiing. Z mapy intenzity aktivity „On Bicycle“ na Slovensku, v Česku a v Poľsku (Príloha 16) sa dá vyčítať to isté a tiež je problém s chybným určením typu aktivity **v lyžiarskych strediskách**. Mapa trajektórií záznamov aktivity „On Bicycle“ **v Olomouci** pomerne dobre zodpovedá realite a je z nej vidieť skutočne časté cyklistické trasy autora práce, napríklad **cez Smetanovy a Čechovy sady smerom na Řepčín**, zo Smetanových sadov smerom na Nemilany a Nedvězí, pozdĺž Bystričky smerom na Bystrovany alebo z areálu Envelopa smerom do Holice.

Z heatmapy aktivity **Na nohách** (On Foot) vidieť, že na nohách sa najviac pohyboval v mestách **Olomouc, Stará Turá a Vroclav**. Z heatmapy aktivity **Beh** (Running) vidieť, že najviac behal v mestách **Olomouc a Vroclav**. Rovnako to vidieť aj z mapy intenzity aktivity „Running“ na Slovensku, v Česku a v Poľsku (Príloha 17). Táto mapa však zobrazuje oblasti intenzity tejto aktivity aj v iných oblastiach, ktoré nie sú pravdivé a jednalo sa v ich prípade buď o rýchlu chôdzu alebo o lyžovanie. V mape trajektórií záznamov aktivity „Running“ najhrubšia línia **na ulici trída Kosmonautů** smerom na železničnú stanicu v skutočnosti nepredstavuje beh, ale rýchlu chôdzu, pretože autor ide na vlak vždy na poslednú chvíľu a nestíha. Z heatmapy aktivity **Chôdza** (Walking) vidieť, že chodil najviac v mestách Olomouc a Stará Turá a rád chodí aj po horách a často chodil aj v mestách, ktoré navštívil. Z mapy intenzity jeho aktivity „Walking“ na Slovensku, v Česku a v Poľsku (Príloha 18) je poznať, že najviac chodil po mestách **Olomouc a Stará Turá**, o niečo menej po meste **Vroclav**. Vyššie hodnoty intenzity badať tiež v Tatrách, Bystrických horách, Prahe či Košiciach. Mapa trajektórií záznamov aktivity „Walking“ je trochu zvláštna, ale dá sa z nej vidieť, že autor veľmi často chodil **z internátu generála Svobody okolo Pevnosti Poznání do centra mesta**.

Z heatmapy **neznámej aktivity** (Unknown) vidieť, že najviac neznámych aktivít sa vykytuje v **Starej Turej a v Olomouci**, teda v lokalitách, kde sa autor najviac zdržiaval

Z heatmapy **preklápania mobilného zariadenia** (Tilting) vidieť, že mobilné zariadenie sa mu najviac preklápalo **v Starej Turej, Olomouci, Vroclave, v Tatrách a v Košiciach**.

Ako autor môžem zhodnotiť, že **najväčšie chyby** v určení typu aktivity sa vyskytujú **v lyžiarskych strediskách**, kde boli jazde lanovkou priradené rôzne typy

dopravných prostriedkov a jazde na lyžiach bol priradovaný typ aktivity „On Bicycle“. Keďže mám dosť rýchle tempo chôdze, typ aktivity „Running“ bol v mojich záznamoch často pridelený neprávne namiesto „Walking“ a hoci som behal len v Olomouci a Vroclave, v heatmape sa objavujú intenzity aktivity aj v iných lokalitách. Nie všetky výstupy z programu V-Analytics majú skutočnú výpovednú hodnotu. Z vytvorených máp aktivity autora práce sa k realite najviac približuje mapa trajektórií aktivity „On Bicycle“.

História polohy (Burian 24.5.2017 – 18.2.2019)

V heatmape **celkovej aktivity** vedúceho práce vidieť, že v priebehu zaznamenávania histórie polohy sa najviac zdržiaval **v Olomouci**, ale dosť času strávil **aj v Štiavnických vrchoch, v Maribore, Bochumi a Amsterdame**. Z mapy intenzity celkovej aktivity vedúceho práce (Príloha 19) môžeme vidieť, že počas zaznamenávania histórie polohy trávil v rámci Českej republiky najviac času v Olomouci. Z mapy trajektórií záznamu celkovej aktivity vedúceho práce v Olomouci je vidieť, **že najčastejšie sa pohybuje medzi katedrou geoinformatiky a sídliskom Řepčín**, kde pravdepodobne býva. Zo svojho domu často chodí nakupovať do nákupného centra **Globus** a z katedry zas do nákupného centra **Šantovka**.

Z heatmapy jeho aktivity **V pokoji** (Still) vidíme, že najviac času v pokoji na jednom mieste strávil **v Olomouci a v Maribore**. V mape intenzity jeho aktivity „Still“ v Česku (Príloha 20) dominuje mesto **Olomouc**.

Z heatmapy aktivity **Vo vozidle** (In Vehicle) vidíme, že **z Olomouca často chodil do Tatier, do Náměšti nad Oslavou a do Jeseníkov**. Rovnaké pozorovanie sa dá vyvodiť aj z mapy intenzity jeho aktivity „In Vehicle“ v Česku (Príloha 21). Z mapy trajektórií záznamu jeho aktivity „In Vehicle“ **v Olomouci** je vidieť, že dopravnými prostriedkami sa často premiestňuje **z katedry do miesta svojho bydliska a odtiaľ do nákupného centra Globus**.

V heatmape aktivity **V cestnom vozidle** (In Road Vehicle) sa vynímajú trasy **z Olomouca do Náměšti nad Oslavou a do Jeseníkov**. Z heatmapy aktivity **V koľajovom vozidle** (In Rail Vehicle) vidieť, že vlakom **z Olomouca často chodil do Prahy a do Mariboru**. Heatmapa aktivity **V štvorkolesovom vozidle** (In Four Wheels Vehicle) nám hovorí, že autom najčastejšie **jazdil do Jeseníkov, Tatier, Náměšti nad Oslavou a Rakúskych Álp**.

Najväčšia intenzita aktivity **Vychádzanie z vozidla** (Exiting Vehicle) sa dá pozorovať **v Olomouci**. Okrem toho vedúci práce často vychádzal z vozidla aj **v Tatrách a v Štiavnických vrchoch**.

Na bicykli (On Bicycle) sa podľa heatmáp najviac pohyboval **v Olomouci, v Žďárskych vrchoch a Štiavnických vrchoch**. Z mapy intenzity jeho aktivity „On Bicycle“ v Česku (Príloha 22) vidieť, že najviac na bicykli jazdil hlavne **v Olomouci, odkiaľ sa presúval aj do Jeseníkov**. Jazdil taktiež **na Vysočíne a v okolí Hostýna**. Z mapy trajektórií záznamu jeho aktivity „On Bicycle“ **v Olomouci** sa zdá, že najčastejšie jazdil po spodnej časti inline okruhu **Hejčínské louky**.

Intenzita aktivity **Na nohách** (On Foot) bola podľa heatmáp najvyššia **v Olomouci, v Tatrách, Jeseníkoch a Maribore**. Z heatmapy aktivity **Beh** (Running) je pekne vidieť, že vedúci práce si rád zabehá všade, kam príde. Vysoké intenzity aktivity sa dajú pozorovať **v Olomouci, v Jeseníkoch, Tatrách, na strednom Slovensku, v Maribore, Amsterdame a Eberswalde pri Berlíne**. V mape intenzity tejto aktivity v Českej republike (Príloha 23) sa dá pozorovať, že behal najviac v Olomouci a v Jeseníkoch.

V rámci Olomouca podľa mapy trajektórií záznamu jeho aktivity „Running“ najčastejšie behal **z Řepčína na KGI a odtiaľ na Svätý Kopeček a do Radíkova**, celá mapa však vyzerá zvláštne a podozrivo. Z mapy intenzity aktivity **Chôdza** (Walking) vidieť, že kráčal najviac **v Olomouci a v Tatrách**. Podľa mapy intenzity jeho aktivity „Walking“ v Česku (Príloha 24), chodil najviac po Olomouci a jeho okolí, **po Jeseníkoch a po Prahe**. **V rámci Olomouca** podľa mapy trajektórií záznamu jeho aktivity Walking (Príloha) najčastejšie chodí **z katedry geoinformatiky do miesta svojho bydliska v Řepčine**, ale používa pri tom inú trasu, než pri jazde dopravným prostriedkom.

Z heatmapy **neznámej aktivity** (Unknown) vidíme, že najviac záznamom bola priradená jej vysoká pravdepodobnosť **v Olomouci**, čo však neznamená to, že by bol v Olomouci zlý signál, ale hlavne to, že v tomto meste trávil vedúci práce najviac času.

Z heatmapy **preklápania mobilného zariadenia** (Tilting) vidieť, že uhol mobilného zariadenia vzhľadom ku gravitácii sa mu najčastejšie menil **v Olomouci**, teda v meste, kde trávil aj najviac času.

História polohy v Olomouci (Študenti KGI 1.1.2019 – 26.3.2019)

Z heatmapy **celkovej aktivity** študentov KGI **v Olomouci** vidíme, že študenti najviac času v sledovanom období trávili **na Katedre geoinformatiky a v areáli Envelopa**. Často sa zdržiavali aj **na železničnej stanici**. Ďalšími oblasťami častého výskytu sú zrejme **lokality, kde v Olomouci bývajú**. Podobné zistenie sa dá pozorovať aj z analógovej mapy (Príloha 25). Z mapy trajektórií záznamu ich celkovej aktivity v Olomouci je vidieť, že najčastejšie sa pohybujú **zo železničnej stanice na katedru a odtiaľ ďalej do centra mesta, nákupného strediska Šantovka a lokalít, kde v Olomouci bývajú**.

V pokoji (Still) študenti najviac času v Olomouci trávili **na katedre, v menze, na internátoch generála Svobody a Bedřicha Václavky** a v iných lokalitách, **kde bývajú**. Ukazuje nám to webová aplikácia a rovnako aj analógová mapa (Príloha 26).

Vo vozidle (In Vehicle) sa študenti pohybovali po celom meste, ako dosť frekventovaná sa javí **trasa z katedry na železničnú stanicu**, z analógovej mapy (Príloha 27) sa ako dosť frekventovaná javí aj **trasa ďalej na autobusovú stanicu**. Z mapy trajektórií tejto aktivity sú viditeľné aj trasy do centra a do lokalít, kde študenti bývajú, frekventovaná je taktiež **výpadovka z mesta smerom na Ostravu**.

Z heatmapy aktivity **V cestnom vozidle** (In Road Vehicle) vidieť, že pomerene častými výpadovkami z mesta sú **cesta 35 smerom do Ostravy a cesta 46 smerom do Šternberka**. Heatmapa aktivity **V koľajovom vozidle** (In Rail vehicle) sa nedá považovať za úplne dôveryhodnú, keďže jej najväčšia intenzita sa dá pozorovať **na katedre geoinformatiky** a došlo tu zjavne k chybnému určeniu typu aktivity. V heatmape aktivity **V štvorkolesovom vozidle** (In four Wheels Vehicle) podobne ako v prípade cestného vozidla dominujú **výpadovky do Šternberka a do Ostravy**.

V heatmape aktivity **Vychádzanie z vozidla** (Exiting Vehicle) vidno, že študenti z vozidla najčastejšie vychádzali **v blízkosti katedry**.

Ako najfrekventovanejšia trasa **na bicykli** (On Bicycle) sa z webovej aj analógovej (Príloha 28) heatmapy javí trasa **z katedry geoinformatiky na sídlisko Nová Ulice**. Z mapy trajektórií záznamov aktivity „On Bicycle“ (Príloha) sa zas zdá, že na bicykli najčastejšie jazdia po **Bezručových a Smetanových sadoch**.

Na nohách (On Foot) sa podľa heatmapy študenti najviac pohybujú **z katedry na železničnú stanicu a na sídlisko Neředín**. **Beh** (Running) je frekventovaný **pozdĺž rieky Morava** smerom k sídlisku Nové Sady a taktiež **v okolí sídlisk Nová Ulice a Neředín**. V analógovej mape (Príloha 29) sa tento typ aktivity ako frekventovaný javí

v centre mesta, na sídlisku Neředín a **v okolí Svatého Kopečka**. Mapa trajektórií záznamov aktivity „Running“ (Príloha) nevyzerá veľmi dôveryhodne a vyplýva z nej, že študenti najviac behali z katedry geoinformatiky na sídlisko Neředín. **Chôdza** (Walking) je podobne ako celá aktivita **Na nohách** (On Foot) podľa webovej mapy najfrekventovanejšia **medzi železničnou stanicou, katedrou a sídliskom Neředín**, podľa analógovej mapy (Príloha 30) **medzi katedrou, centrom mesta a železničnou stanicou**. Z mapy trajektórií záznamov aktivity „Walking“ v Olomouci (Príloha) sa dá vyčítať, že študenti najčastejšie chodia **zo železničnej stanice na katedru a odtiaľ ďalej do Šantovky a na sídliská Nová Ulice a Neředín**.

Neznámy typ aktivity (Unknown) bol najčastejšie priradený v lokalitách, kde študenti trávili najviac času, teda **na katedre, na železničnej stanici** a v lokalitách, **kde bývajú**.

Podobne aj **preklápanie mobilného zariadenia** (Tilting) bolo najčastejšie tam, **kde sa študenti najviac zdržiavali**.

Pravdivosť vzniknutých webových, analógových a digitálnym máp neviem vyhodnotiť, musel by som ju na to z každým študentom zvlášť prekonzultovať, čo by zabralo dosť veľké množstvo času. Viem však určite povedať, že záznam aktivity „In Rail Vehicle“ sa v značnej miere nezhoduje s realitou a mapy líniových trajektórií aktivít „On Bicycle“ a „Running“ nevyzerajú príliš dôveryhodne.

6 DISKUSIA

V tejto práci boli overované možnosti využitia dát služby Google Location pre časopriestorové analýzy pohybu osôb. Pracovalo sa s dátami autora práce, vedúceho práce a pätnástich študentov katedry geoinformatiky. Pri ich spracovaní boli využité a súčasne boli počas práce rozšírené odborné zručnosti z programovania, práce v štatistických softvéroch a geografických informačných systémoch.

Ak by sa mali vytvoriť vizualizácie priestorových vzorcov pohybu v rámci mesta, bolo by na to určite dáta od väčšieho množstva ľudí. Cieľom práce však bolo hlavne zistiť, či sú dáta pre takýto typ analýz použiteľné. Témou práce, ktorá by na túto nadväzovala, by mohla byť analýza priestorových vzorcov pohybu väčšej skupiny osôb v rámci mesta Olomouc na základe dát z Google Location.

Práca so záznamom histórie polohy získaným stiahnutím z Google Location bola komplikovaná a vyžadovala si veľké množstvo trpezlivosti. Štruktúra záznamu ani po konverzii do formátu SHP nebola taká, ako sa pôvodne predpokladalo a namiesto jasne stanoveného typu aktivity je priradená každému typu aktivity určitá hodnota pravdepodobnosti. Po vyskúšaní rôznych hodnôt pravdepodobnosti ako hraničných pre určenie typu aktivity bolo rozhodnuté, že touto hodnotou bude 50. Nevýhodou takéhoto rozhodnutia bolo, že väčšina bodov zostala bez určenia typu aktivity. Z tohto dôvodu bolo problematické vytvoriť líniové záznamy aktivity. Hľadanie spôsobu, ako priradiť väčšiemu množstvu dát typ aktivity a výskum rôznych možností vytvorenia líniového záznamu aktivity z dát z Google Location môže byť témou ďalších bakalárskych či diplomových prác.

Na určenie prekrývania hodnôt pravdepodobnosti pre jednotlivé typy aktivity bola použitá metóda boxplotov, s ktorou sa autor oboznámil v prvom ročníku štúdia na hodinách štatistiky. Dá sa predpokladať, že existujú aj profesionálnejšie štatistické metódy určenia prekrývania hodnôt atribútov. Taktiež sa dá predpokladať, že existujú iné spôsoby, ktorými by sa dala štruktúra záznamu histórie polohy štatisticky analyzovať a ktoré neboli použité. Podrobnejšia štatistická analýza dát z Google Location môže byť predmetom výskumu ďalších prác.

Primárne zameranie tejto práce nie je kartografické a preto výber stupnice vo webových mapových aplikáciách zobrazujúcich intenzitu jednotlivých aktivít nie je kartograficky najsprávnejší. Webové mapy intenzity typov aktivity si užívateľ súčasne môže nesprávne interpretovať, pretože na vyjadrenie intenzity záznamov, ktorých boli pre jednotlivé aktivity rôzne počty, bola použitá vždy rovnaká stupnica. Je to spôsobené nemožnosťou nahrania vlastnej stupnice do ArcGIS Online. Analógové mapy mohli obsahovať viac topografického podkladu, ale väčší dôraz bol kladený na vyjadrenie intenzity aktivít, teda na ich tematický obsah. Tematickým obsahom bola heatmapa, na tvorbu ktorej mohlo byť vyskúšaných viac nástrojov. Cieľom ďalšej práce nadväzujúcej na túto by mohla byť vizualizácia dát z Google Location s využitím širšej palety nástrojov a metód a súčasne s väčším dôrazom na kartografické pravidlá.

Program V-Analytics sa rozhodne nedá považovať za kartografický, ale výstupy z neho boli upravené tak, aby obsahovali aspoň základné mapové kompozičné prvky. Ku zväčšeniu výpovednej hodnoty máp z V-Analytics by rozhodne prispelo to, keby sa venoval väčší čas predpríprave dát pred ich nahraním do tohto programu. Cieľom ďalšej práce, ktorá by na túto nadväzovala, by mohlo byť práve dôkladnejšie spracovanie dát z Google Location vo V-Analytics.

Slovná interpretácia výsledkov sa snažila odhadnúť, aké činnosti autor práce, vedúci práce a študenti katedry v priebehu zaznamenávania histórie vykonávali a v prípade autora a vedúceho práce aj odhady porovnať s realitou. Nadstavbou k tomuto v ďalšej práci by mohlo byť, že respondenti by si v priebehu nejakého časového obdobia zaznamenávali svoju aktivitu a zmeny svojej polohy do dotazníka a po stiahnutí dát z Google Location by ich dáta boli porovnané s realitou.

Pri porovnávaní najmä vizualizácií pohybu autora s realitou sa zistilo, že problém dát z Google Location je, že neobsahujú kategórie pre niektoré typy aktivity, napríklad lyžovanie a preto sú pri lyžovaní priradované vysoké hodnoty pravdepodobnosti rôznym iným typom aktivity. Témou ďalšej práce by mohlo byť navrhnutie nových typov aktivity, ktoré by mohli byť do záznamu z Google Location pridané.

Bolo predstavených niekoľko spôsobov, ako by sa práca na tému analýzy a vizualizácie dát služby Google Location dala ďalej rozvíjať a keďže ma daná problematika veľmi zaujala, vedel by som si predstaviť, že by som ju sám rozvinul v rámci svojej diplomovej práce.

7 ZÁVER

Hlavným cieľom bakalárskej práce bolo otestovať možnosti využitia dát služby Google Location pre časopriestorové analýzy pohybu osôb.

Na začiatku boli preštudované metódy záznamu dát služby Google Location a metódy analýzy dát z GPS trajektórií a dotazníkov, ktoré je možné použiť na identifikáciu priestorových vzorcov pohybu osôb.

Dáta boli z Google Location stiahnuté vo formáte JSON. Existuje rovnako aj možnosť stiahnuť dáta vo formáte KML, avšak takémuto záznamu chýba značná časť informácií, ktorá sa v zázname vo formáte JSON nachádza. Pomocou skriptu v jazyku python, ktorý bol získaný z GitHubu a následne čiastočne upravený, boli dáta prekonvertované do formátu GEOJSON. V programe QGIS boli následne prekonvertované do formátu SHP.

Pozorovaním dát z vlastného záznamu bola určená hodnota odchýlky a s dátami s vyššou odchýlkou sa ďalej nepracovalo. Ďalej bola určená hraničná hodnota pravdepodobnosti aktivity, na základe ktorej bolo následne určené, aké typy aktivity priradiť jednotlivým bodom. Keď sa zistilo, že s dát sa dajú takýmto spôsobom vybrať použiteľné záznamy, nad ktorými bude možné prevádzať ďalšie analýzy, boli rovnakým spôsobom odstránené dáta s veľkou odchýlkou aj zo záznamu vedúceho práce a rovnako v ňom boli podľa pravdepodobnosti určené aj typy aktivity.

Keďže bolo vidieť, že dáta sú pre analýzy a vizualizácie použiteľné, bolo rozhodnuté, že budú vytvorené aj analýzy priestorových osôb pohybu študentov KGI v Olomouci. Pre tieto účely boli získané záznamy histórie polohy od 15 študentov KGI. Tieto dáta boli po konverzii spojené do jedného súboru, z ktorého boli vybrané záznamy pre mesto Olomouc v určitom časovom období. Ďalej boli dáta spracované rovnako ako dáta autora práce a vedúceho práce.

Prvá časť štatistických analýz bola vytvorená v programe MS Excel. Ich výsledky ukazujú, aké presné sú dáta autora práce, vedúceho práce a študentov KGI, akým počtom bodov boli priradené jednotlivé typy aktivity a akému veľkému počtu bodov nebolo možné priradiť typ aktivity.

Druhá časť štatistických analýz bola vytvorená v programe RStudio. Ich výsledkami sú boxploty ukazujúce, v akom rozpätí sa pri jednotlivých typoch aktivity pohybujú ich hodnoty pravdepodobnosti a hodnoty pravdepodobnosti iných aktivít.

Z kartografických vizualizácií boli ako prvé vytvorené webové mapové aplikácie. Boli vytvorené 3 mapové aplikácie zobrazujúce heatmappy celkovej aktivity a všetkých typov aktivity autora práce, vedúceho práce a študentov KGI. Ďalej boli vytvorené 2 mapové aplikácie, ktoré formou animácie zobrazujú pohyb autora práce a vedúceho práce v priebehu 12 mesiacov. Ďalej boli vytvorené papierové tematické mapy zobrazujúce intenzitu celkovej aktivity a piatich vybraných typov aktivity. Z dát autora práce boli tieto mapy vytvorené pre územie Česka, Slovenska a Poľska, z dát vedúceho práce pre územie Česka a z dát študentov KGI pre územie mesta Olomouc. Ako posledný typ vizualizácie boli v programe V-Analytics vytvorené digitálne tematické mapy zobrazujúce líniové trajektórie celkového pohybu a štyroch vybraných typov aktivity autora práce, vedúceho práce a študentov KGI.

Výsledky štatistických analýz a kartografických vizualizácií boli na záver interpretované a pokiaľ to bolo možné aj porovnané so skutočnosťou. Ciele zadané na začiatku práce boli splnené a individuálne priestorové vzory popisujúce dopravné správanie sa podarilo popísať.

POUŽITÁ LITERATÚRA A INFORMAČNÉ ZDROJE

Allahviranloo, M. and Recker, W. (2015). Mining activity pattern trajectories and allocating activities in the network. *Transportation*, 42(4), pp.561-579. doi:10.1007/978-3-319-67585-5_80.

Boates, I. *GitHub* [online]. 2019 [cit. 2019-03-17]. android_location_converter. Dostupné z WWW: < https://github.com/iboates/android_location_converter >

Burian, J., Zajičková, L., Ivan, I. and Macků, K. (2018). Attitudes and Motivation to Use Public or Individual Transport: A Case Study of Two Middle-Sized Cities. *Social Sciences*, 7(6), p.83.

FRANTÁL, B. *Prostorové chování: vzorce aktivit, mobilita a každodenní život ve městě*. Brno: Masarykova univerzita, 2012. ISBN 978-80-210-5756-2.

FUSKOVÁ, D. *Bakalárska práca: Dana Fusková* [online]. 2014 [cit. 2019-01-28]. Geoinformace v prostředí sociálních sítí. Dostupné z WWW: < <http://www.geoinformatics.upol.cz/dprace/bakalarske/fuskova14/> >

Google Developers. [online]. 2019 [cit. 2019-02-23]. *DetectedActivity* | *Google APIs for Android* | *Google Developers* Dostupné z WWW: < <https://developers.google.com/android/reference/com/google/android/gms/location/DetectedActivity#constant-summary> >

Gianotti, F., Nanni, M., Pedreschi, D. and Pinelli, F. (2007). Trajectory Pattern Mining. *Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '07*, pp.330-339. New York, New York, USA: ACM Press. doi:10.1145/1281192.1281230.

Patt, T. *GitHub* [online]. 2019 [cit. 2019-04-29]. location-history-visualizer. Dostupné z WWW: < <https://github.com/theopolisme/location-history-visualizer> >

JARCOVJÁK, D. *Bakalárska práca: David Jarcovjác* [online]. 2013 [cit. 2019-01-28]. Testování aplikace foursquare pro sledování pohybu osob v Olomouci. Dostupné z WWW: < <http://www.geoinformatics.upol.cz/dprace/bakalarske/jarcovjak13/> >

Krumm, J. and Horvitz, E. (2006). Predestination: Inferring Destinations from Partial Trajectories. *The Eighth International Conference on Ubiquitous Computing*, pp.243-260. doi:10.1007/11853565_15.

LIAO, L., PATTERSON, D., FOX, D. and KAUTZ, H. (2006). Building Personal Maps from GPS Data. *Annals of the New York Academy of Sciences*, 1093(1), pp.249-265. doi:10.1196/annals.1382.017

Mathur, K. *Analyzing my Google Location History*. [online]. 2019.[cit. 2019-03-01]. Towards Data Science. Dostupné z WWW: <<https://towardsdatascience.com/analyzing-my-google-location-history-d3a5c56c7b70>>

Naserian, E., Wang, X., Dahal, K., Wang, Z. and Wang, Z. (2018). Personalized location prediction for group travellers from spatial-temporal trajectories. *Future Generation Computer Systems*, 83, pp.278-292. doi:10.1016/j.future.2018.01.024.

Oglesby, C. Analyze Your Google Location History: Exploring Data. [online]. [cit. 2019-03-01]. Chip Oglesby. Dostupné z WWW: <<https://www.chipoglesby.com/2018/03/2018-analyzing-google-location-historyII/>>

POJSL, L. *Bakalárska práca: Lukáš Pojsl* [online]. 2014 [cit. 2019-05-03]. Každodenní prostorová mobilita obyvatel ve městě Strakonice: vzorce individuální mobility a jejich studium pomocí moderních geoinformačních technologií. Dostupné z WWW: <<https://theses.cz/id/hrpnk7/?furl=%2Fid%2Fhrpnk7%2F;so=nx;lang=en>>

ROUBALÍK, Š. *Bakalárska práca: Štěpán Roubalík* [online]. 2017 [cit. 2019-01-28]. Analýza toků veřejné dopravy na základě dat z mýtných bran. Dostupné z WWW: <<http://www.geoinformatics.upol.cz/dprace/bakalarske/roubalik17/>>

Salomón, S., Tírňaucá, C., Duque, R., Montaña, J.L. (2017). Daily Routines Inference Based on Location History. *Ubiquitous Computing and Ambient Intelligence*, pp.828-839. doi:10.1007/978-3-319-67585-5_80.

Sohn, T., Varshavsky, A., LaMarca, A., Y. Chen, M., Choudhury, T., Smith, I., Consolvo, S., Hightower, J., G. Griswold, W., de Lara, E. 2006. Mobility Detection Using Everyday GSM Traces. (2006). *Ubiquitous Computing*, pp.212-224. Springer, Berlin, Heidelberg. doi:10.1007/11853565_13.

Support.google.com. (2018). [online]. 2018 [cit. 2018-28-12]. *Manage your Location History - Google Account Help*. Dostupné z WWW: <<https://support.google.com/accounts/answer/3118687?hl=en>>

Thudt, A., Baur, D. and Carpendale, S. (2013). Visits: A Spatiotemporal Visualization of Location Histories. *Eurographics Conference on Visualization (EuroVis) (2013)*, pp.1-5.

VONDRÁKOVÁ, A. *Bakalárska práca: Alena Vondráková* [online]. 2007 [cit. 2019-01-28]. Pohyb městské populace a jeho kartografická vizualizace. Dostupné z WWW: <<http://www.geoinformatics.upol.cz/dprace/bakalarske/vondrakova07/index.htm>>

Wang, Z., He, S. and Leung, Y. (2018). Applying mobile phone data to travel behaviour research: A literature review. *Travel Behaviour and Society*, 11, pp.141-155. doi:10.1016/j.tbs.2017.02.005.

Ye, Y., Zheng, Y., Chen, Y., Feng, J. and Xie, X. (2009). Mining Individual Life Pattern Based on Location History. *Tenth International Conference on Mobile Data Management: Systems*, pp.1-10. IEEE. doi:10.1109/MDM.2009.11.

PRÍLOHY

ZOZNAM PRÍLOH

Viazané prílohy:

- Príloha 1 Počty bodov v zázname autora z Google Location s Accuracy pod 100 podľa typu aktivity a jej pravdepodobnosti
- Príloha 2 Zastúpenie bodov s odchýlkou nad 100 v záznamoch histórie polohy
- Príloha 3 Početnosť aktivít v záznamoch pri hraničnej pravdepodobnosti 50
- Príloha 4 Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity
- Príloha 5 Trajektórie záznamov aktivity v Olomouci

Voľné prílohy

- Príloha 6 Poster
- Príloha 7 DVD
- Príloha 8 Pohyb v priebehu mesiacov roku 2018 (Burian), dostupné na: <http://kgi-upol.maps.arcgis.com/apps/webappviewer/index.html?id=46e22e44e3914684b7d6f838a7349343>
- Príloha 9 Pohyb od mája 2018 do apríla 2019 (Rybnikár), dostupné na: <http://kgi-upol.maps.arcgis.com/apps/webappviewer/index.html?id=28c41c3f22c14b20899860b90b688fd1>
- Príloha 10 História polohy (Rybnikár 2.5.2018 – 17.3.2019), dostupné na: <http://kgi-upol.maps.arcgis.com/apps/webappviewer/index.html?id=625f8c2b7c7b4099a483414ff8384f3f>
- Príloha 11 História polohy (Burian 25.4.2017 – 18.2.2019), dostupné na: <http://kgi-upol.maps.arcgis.com/apps/webappviewer/index.html?id=f4cb00a15f4949a6b925305bd4318890>
- Príloha 12 História polohy v Olomouci (Študenti KGI 1.1.2019 – 26.3.2019), dostupné na: <http://kgi-upol.maps.arcgis.com/apps/webappviewer/index.html?id=4e7836a374d54533a3adff9cdd71b5de>
- Príloha 13 Intenzita všetkých aktivít (Rybnikár)
- Príloha 14 Intenzita aktivity „Still“ (Rybnikár)
- Príloha 15 Intenzita aktivity „In Vehicle“ (Rybnikár)
- Príloha 16 Intenzita aktivity „On Bicycle“ (Rybnikár)
- Príloha 17 Intenzita aktivity „Running“ (Rybnikár)
- Príloha 18 Intenzita aktivity „Walking“ (Rybnikár)
- Príloha 19 Intenzita všetkých aktivít (Burian)
- Príloha 20 Intenzita aktivity „Still“ (Burian)
- Príloha 21 Intenzita aktivity „In Vehicle“ (Burian)
- Príloha 22 Intenzita aktivity „On Bicycle“ (Burian)
- Príloha 23 Intenzita aktivity „Running“ (Burian)
- Príloha 24 Intenzita aktivity „Walking“ (Burian)
- Príloha 25 Intenzita všetkých aktivít (Študenti KGI)
- Príloha 26 Intenzita aktivity „Still“ (Študenti KGI)
- Príloha 27 Intenzita aktivity „In Vehicle“ (Študenti KGI)
- Príloha 28 Intenzita aktivity „On Bicycle“ (Študenti KGI)

Príloha 29 Intenzita aktivity „Running“ (Študenti KGI)

Príloha 30 Intenzita aktivity „Walking“ (Študenti KGI)

Popis štruktúry DVD

Adresáre:

- Scripts (*Pôvodný a upravený python skript*)
- Excel (*Tabuľky a grafy*)
- RStudio (*Skript a boxploty*)
- WebApps (*Odkazy na webové aplikácie*)
- Mapy (*Analógové mapy v PDF*)
- V-Analytics (*Výstupy z programu*)
- Text práce
- Poster
- WEB


Príloha 1: Počty bodov v zázname autora z Google Location s Accuracy pod 100 podľa typu aktivity a jej pravdepodobnosti

Počty bodov v zázname autora z Google Location s Accuracy pod 100 podľa typu aktivity a jej pravdepodobnosti																										
pravdepodobnosť	still		Unknown		In Vehicle		Tilting		On Bicycle		On Foot		Walking		Running		Exiting Vehicle		In Rail Vehicle		In Road Vehicle		In Two Wheels Vehicle		In Four Wheels Vehicle	
100	5553	2,0%	0	0,0%	45	0,0%	7024	2,6%	510	0,2%	777	0,3%	738	0,3%	39	0,0%	60	0,0%	0	0,0%	45	0,0%	0	0,0%	0	0,0%
>=50	8642	3,2%	33	0,0%	1122	0,4%	7024	2,6%	1896	0,7%	4032	1,5%	3713	1,4%	271	0,1%	60	0,0%	114	0,0%	949	0,3%	0	0,0%	562	0,2%
>=25	11999	4,4%	1950	0,7%	2764	1,0%	7024	2,6%	2590	1,0%	5998	2,2%	5709	2,1%	416	0,2%	60	0,0%	890	0,3%	2015	0,7%	8	0,0%	913	0,3%

Druhý stĺpec vždy vyjadruje percentuálne zastúpenie z celkového počtu bodov 271 883


PRESNOSŤ ZÁZNAMU POLOHY (ĽUBOŠ RYBNÍKÁR)

■ Accuracy pod 100 ■ Accuracy nad 100




PRESNOSŤ ZÁZNAMU POLOHY (ŠTUDENTI KGI)

■ Accuracy pod 100 ■ Accuracy nad 100




PRESNOSŤ ZÁZNAMU POLOHY (JAROSLAV BURIAN)

■ Accuracy pod 100 ■ Accuracy nad 100




Príloha 3: Početnosť aktivít v záznamoch pri hraničnej pravdepodobnosti 50

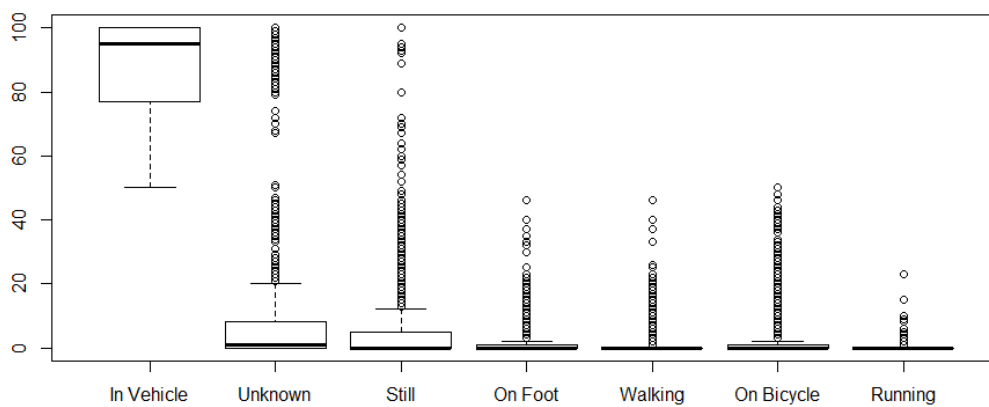


Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity


Istoty aktivít pri istote In Vehicle nad 50 (Rybnikár)



Istoty aktivít pri istote In Vehicle nad 50 (Burian)




Istoty aktivít pri istote In Vehicle nad 50 (spolužiaci)




Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity


Istoty aktivít pri istote On Bicycle nad 50 (Rybnikár)



Istoty aktivít pri istote On Bicycle nad 50 (Burian)

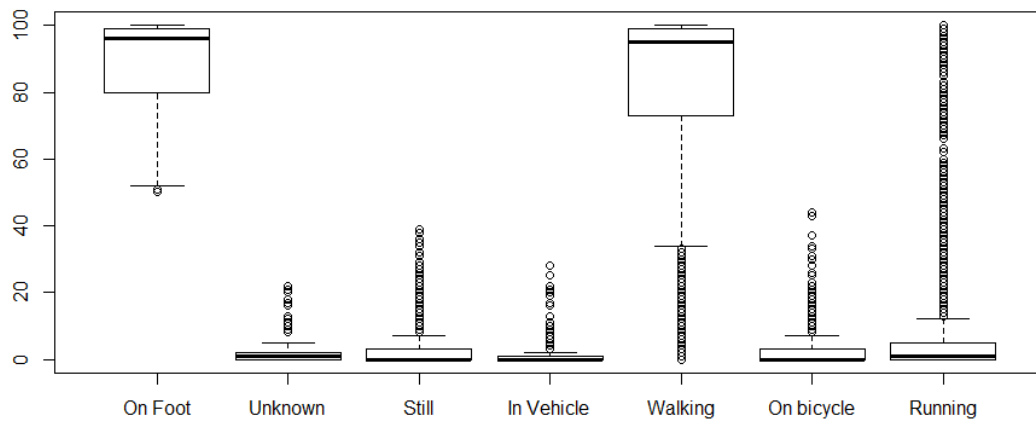


Istoty aktivít pri istote On Bicycle nad 50 (spolužiaci)




Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity


Istoty aktivít pri istote On Foot nad 50 (Rybnikár)



Istoty aktivít pri istote On Foot nad 50 (Burian)




Istoty aktivít pri istote On Foot nad 50 (spolužiaci)




Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity


Istoty aktivít pri istote Running nad 50 (Rybnikár)



Istoty aktivít pri istote Running nad 50 (Burian)




Istoty aktivít pri istote Running nad 50 (spolužiaci)




Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity


Istoty aktivít pri istote Still nad 50 (Rybnikár)



Istoty aktivít pri istote Still nad 50 (Burian)




Istoty aktivít pri istote Still nad 50 (spolužiaci)




Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity


Istoty aktivít pri istote Unknown nad 50 (Rybnikár)



Istoty aktivít pri istote Unknown nad 50 (Burian)




Istoty aktivít pri istote Unknown nad 50 (spolužiaci)




Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity


Istoty aktivít pri istote Tilting nad 50 (Rybnikár)



Istoty aktivít pri istote Tilting nad 50 (Burian)




Istoty aktivít pri istote Tilting nad 50 (spolužiaci)




Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity


Istoty aktivít pri istote Exiting vehicle nad 50 (Rybnikár)



Istoty aktivít pri istote Exiting vehicle nad 50 (Burian)




Istoty aktivít pri istote Exiting vehicle nad 50 (spolužiaci)




Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity


Istoty typov dopravných prostriedkov pri istote In vehicle nad 50 (Rybnikár)



Istoty typov dopravných prostriedkov pri istote In vehicle nad 50 (Burian)




Istoty typov dopravných prostriedkov pri istote In vehicle nad 50 (spolužiaci)




Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity

Istoty typov dopravných prostriedkov pri istote In 2 wheels vehicle nad 50 (Burian)




Istoty typov dopravných prostriedkov pri istote In 2 wheels vehicle nad 50 (spolužiaci)




Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity

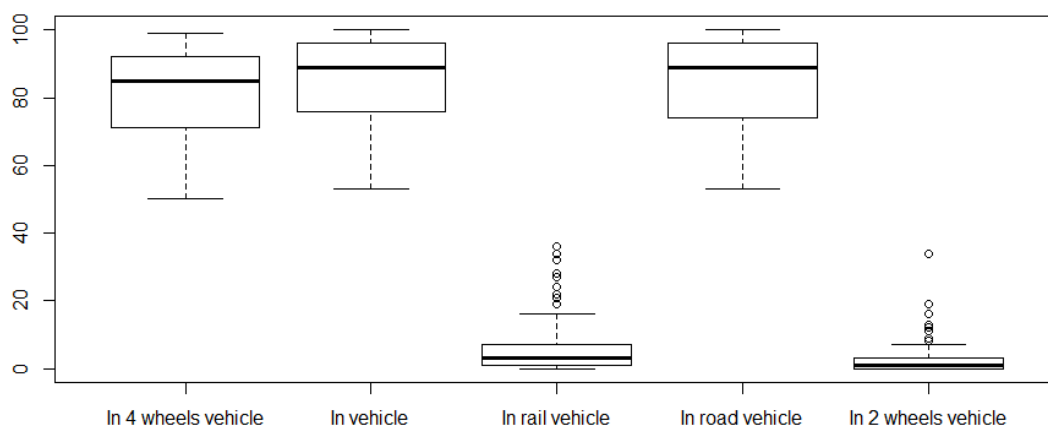
Istoty typov dopravných prostriedkov pri istote In 4 wheels vehicle nad 50 (Rybnikár)



Istoty typov dopravných prostriedkov pri istote In 4 wheels vehicle nad 50 (Burian)




Istoty typov dopravných prostriedkov pri istote In 4 wheels vehicle nad 50 (spolužiaci)

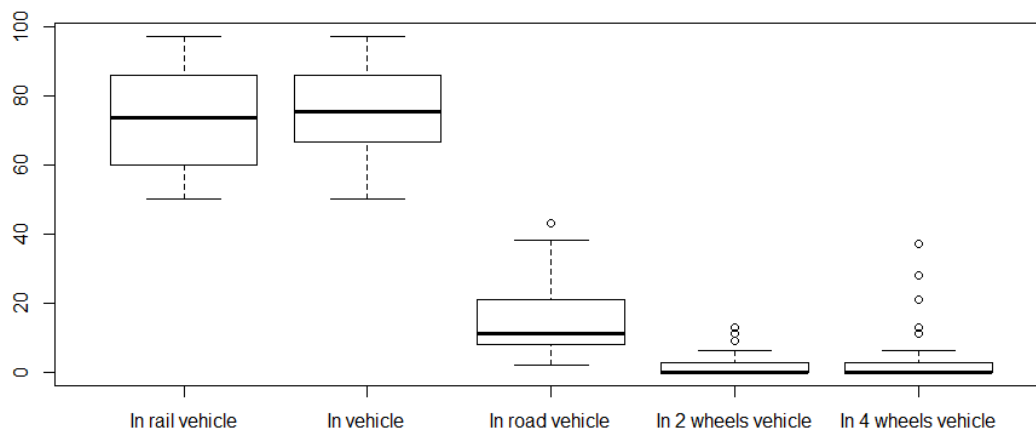


Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity

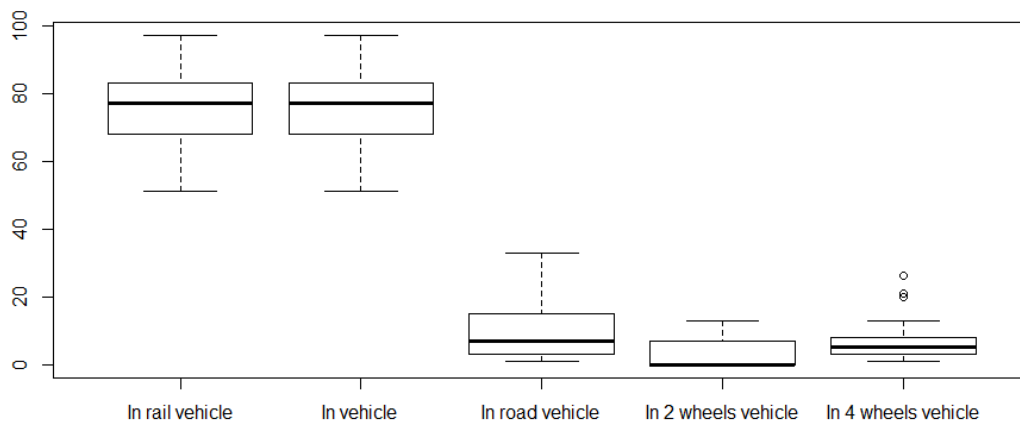
Istoty typov dopravných prostriedkov pri istote In rail vehicle nad 50 (Rybnikár)



Istoty typov dopravných prostriedkov pri istote In rail vehicle nad 50 (Burian)




Istoty typov dopravných prostriedkov pri istote In rail vehicle nad 50 (spolužiaci)




Príloha 4: Rozptyl hodnôt pravdepodobnosti jednotlivých typov aktivity


Istoty typov dopravných prostriedkov pri istote In road vehicle nad 50 (Rybnikár)



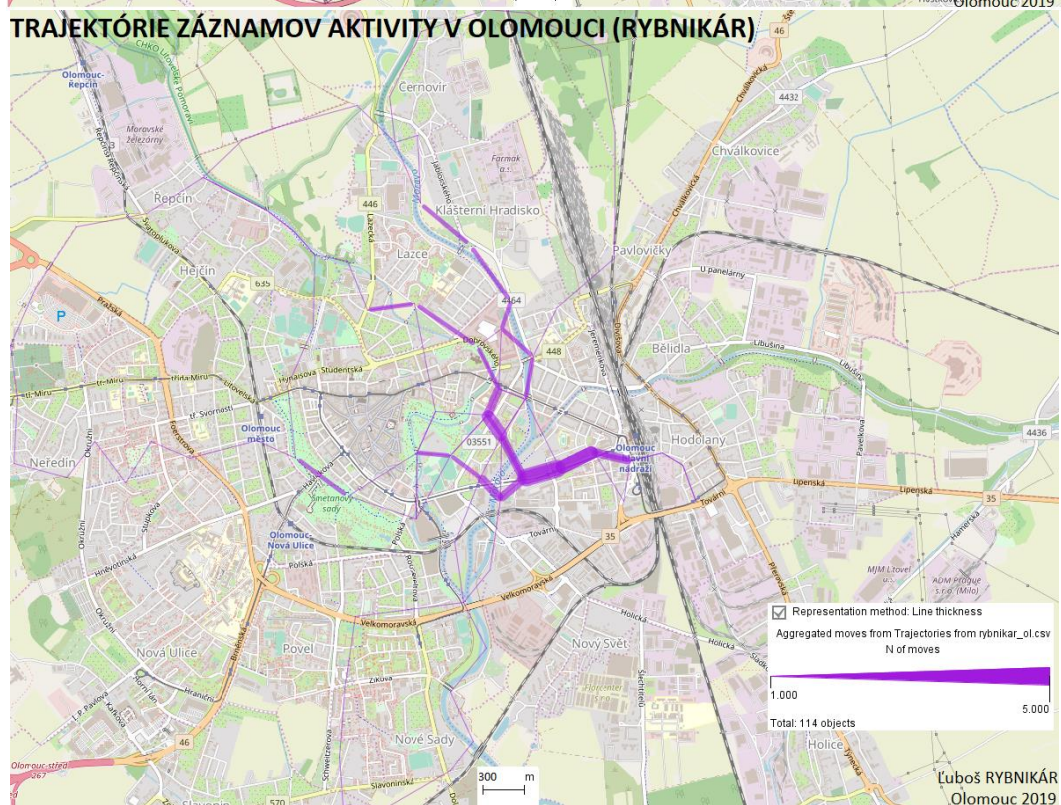
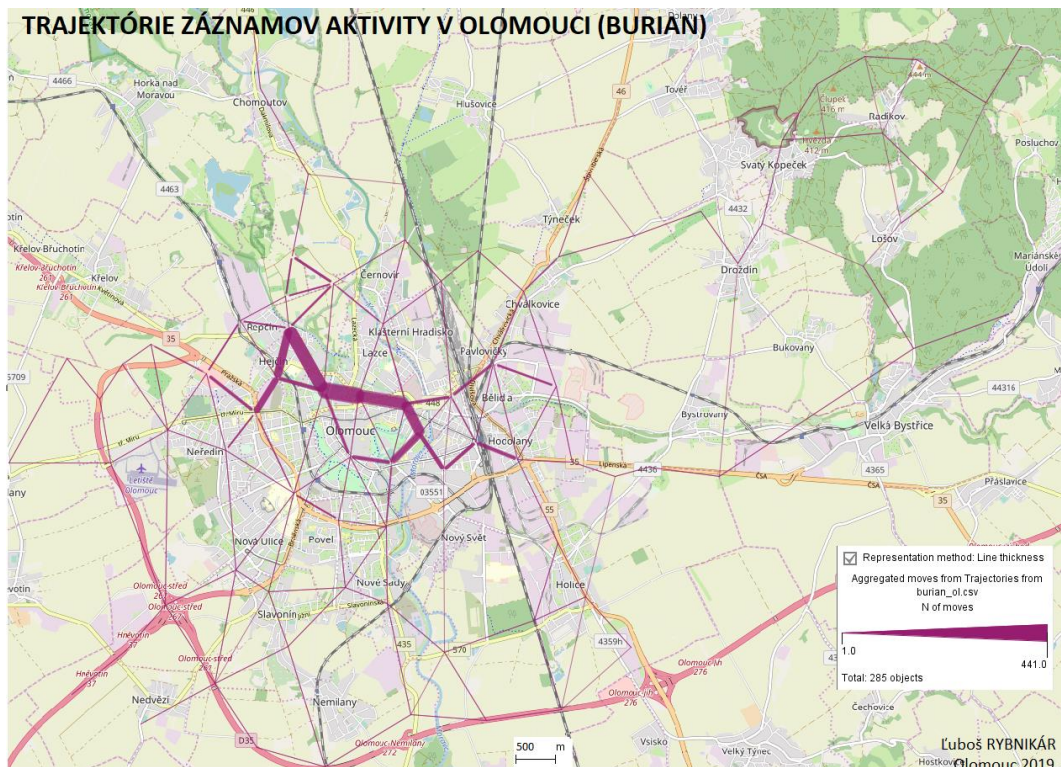
Istoty typov dopravných prostriedkov pri istote In road vehicle nad 50 (Burian)

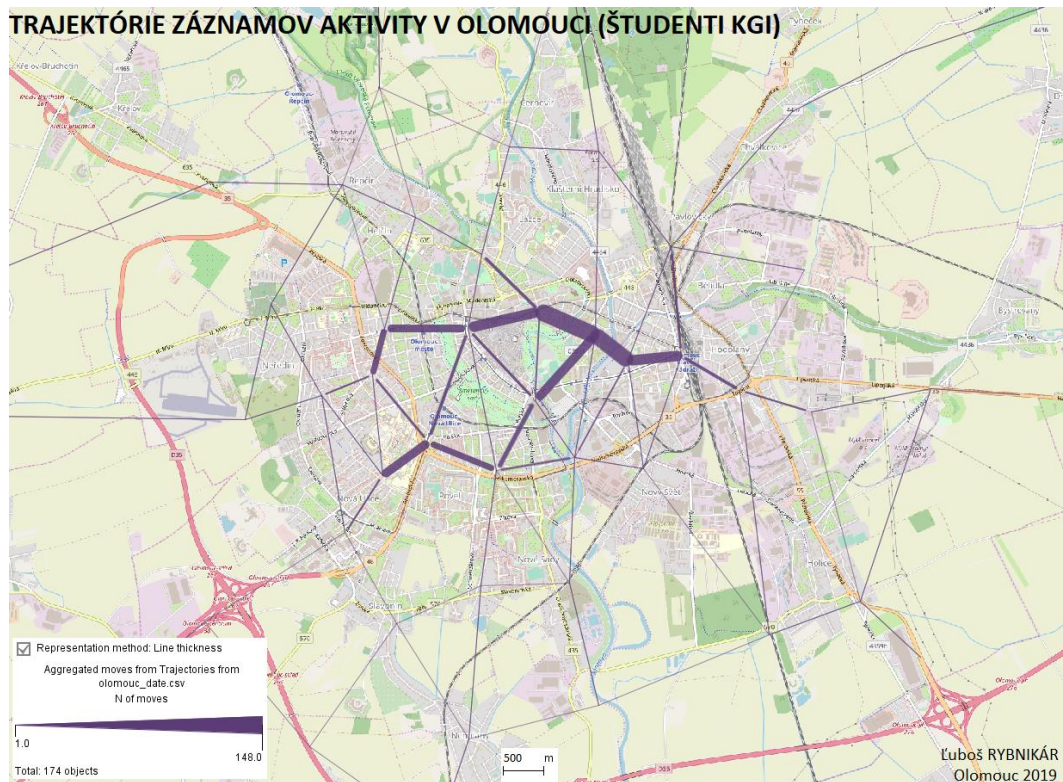


Istoty typov dopravných prostriedkov pri istote In road vehicle nad 50 (spolužiaci)

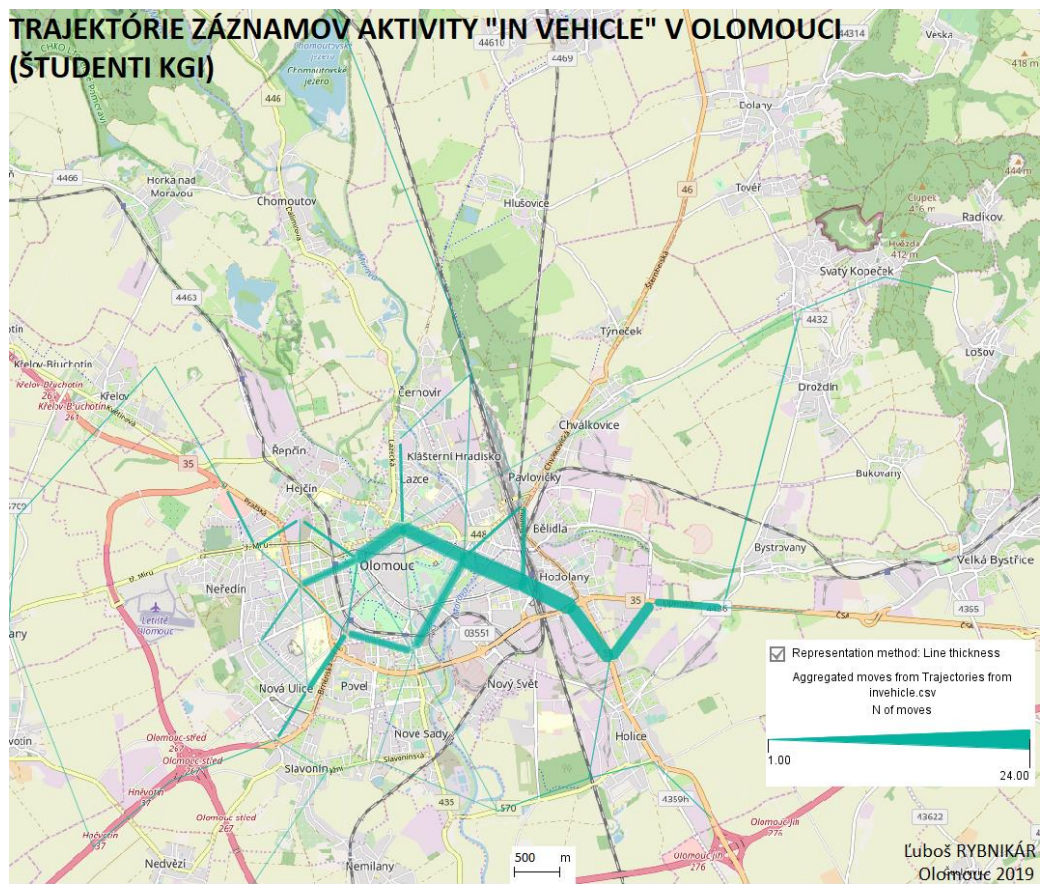
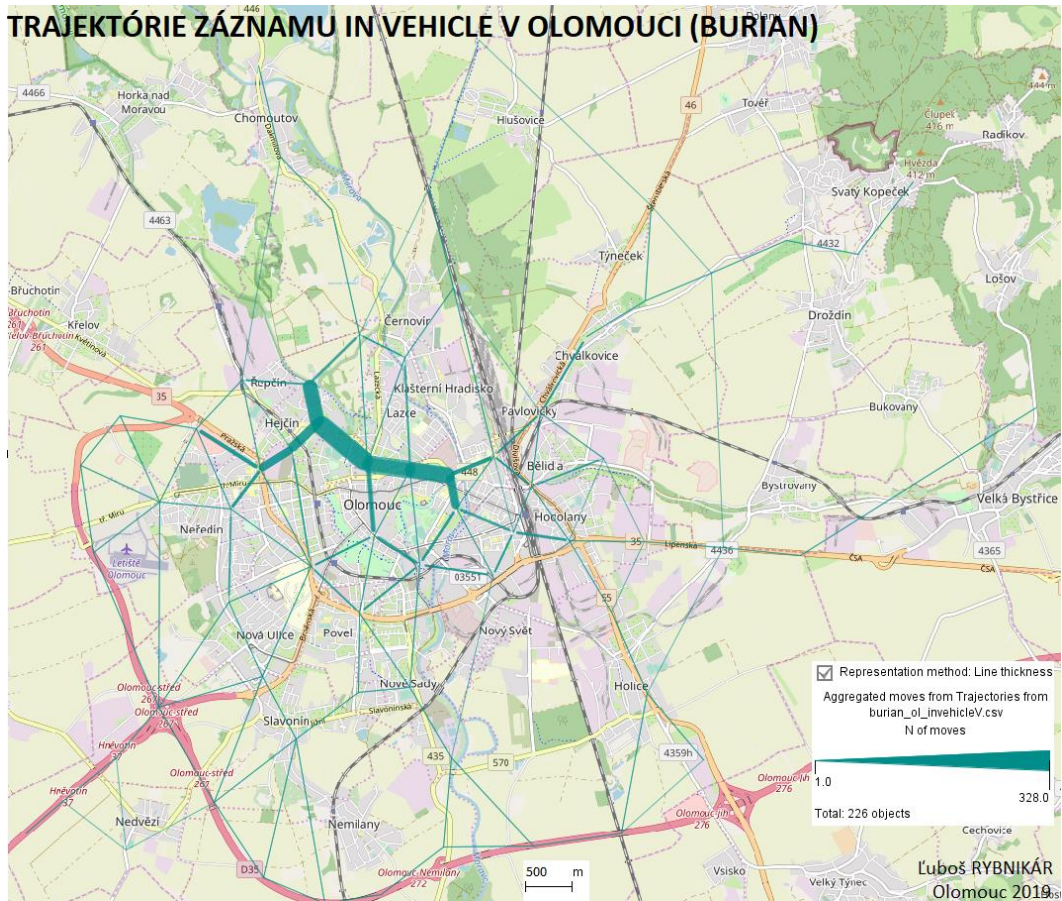


Príloha 5: Trajektórie záznamov aktivity v Olomouci

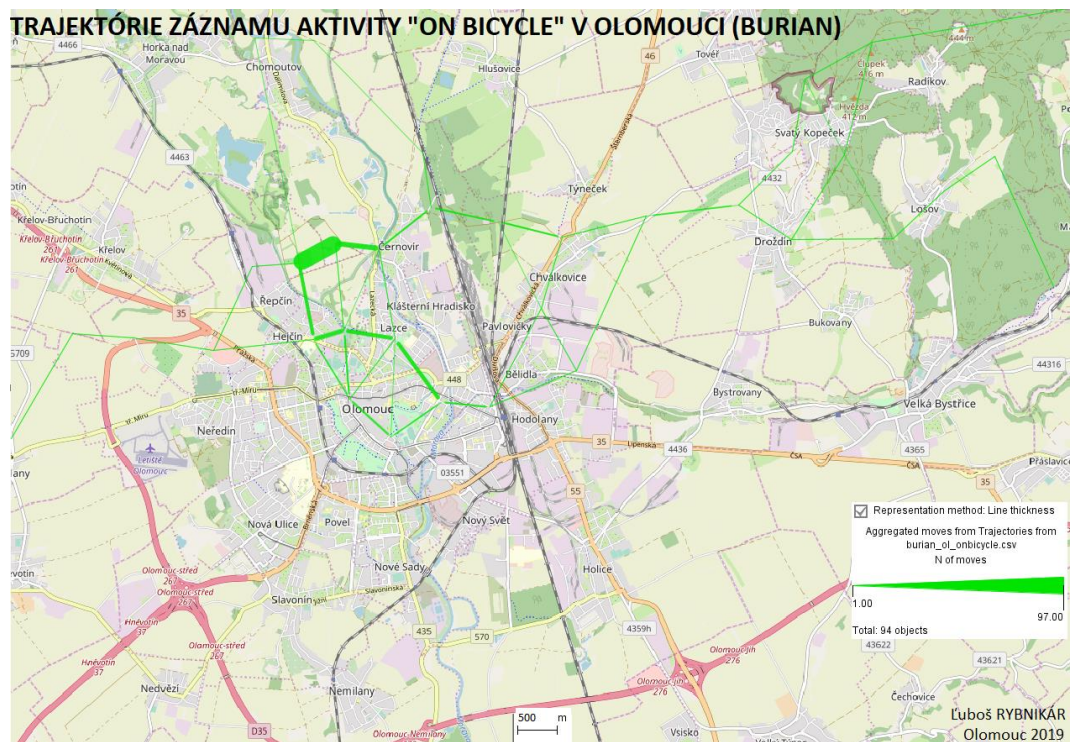
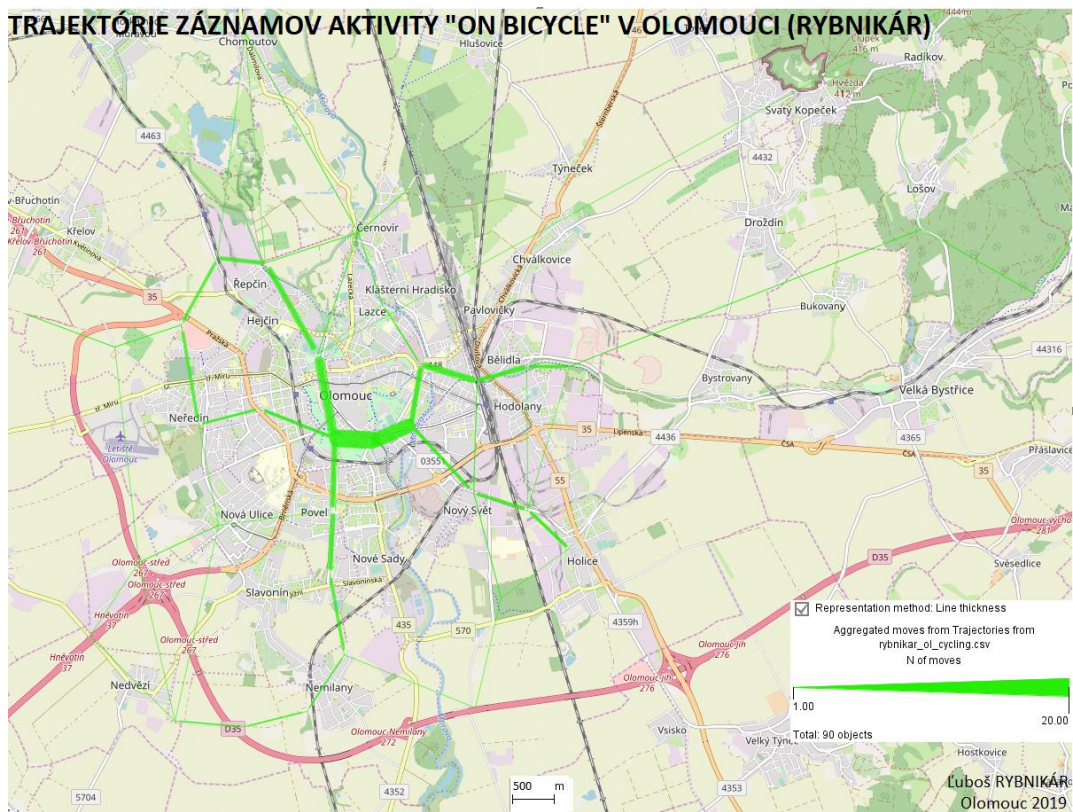




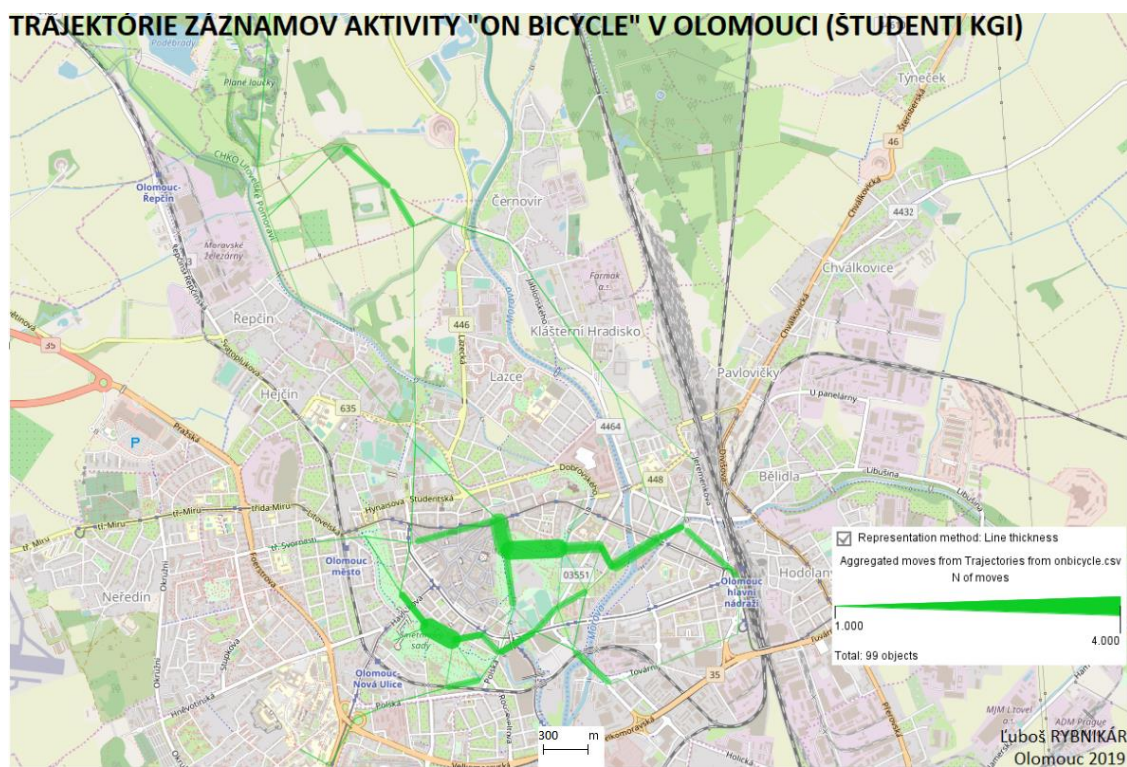
Príloha 5: Trajektórie záznamov aktivity v Olomouci



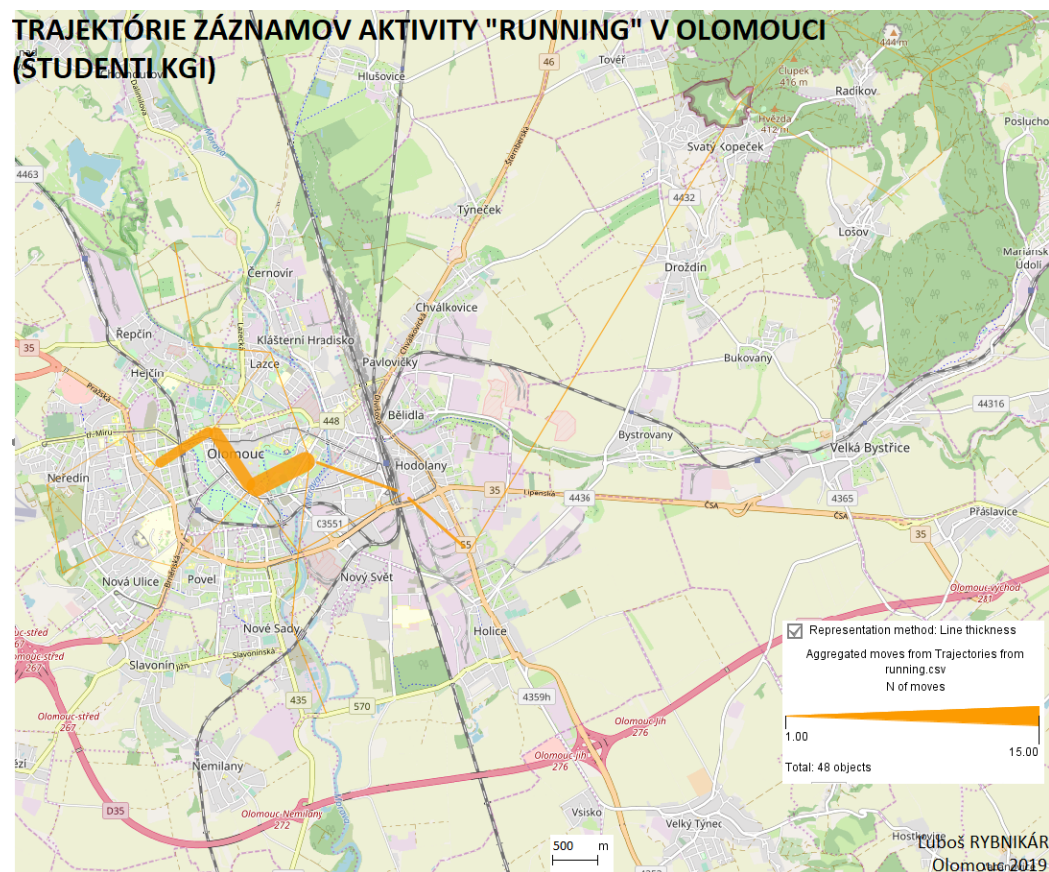
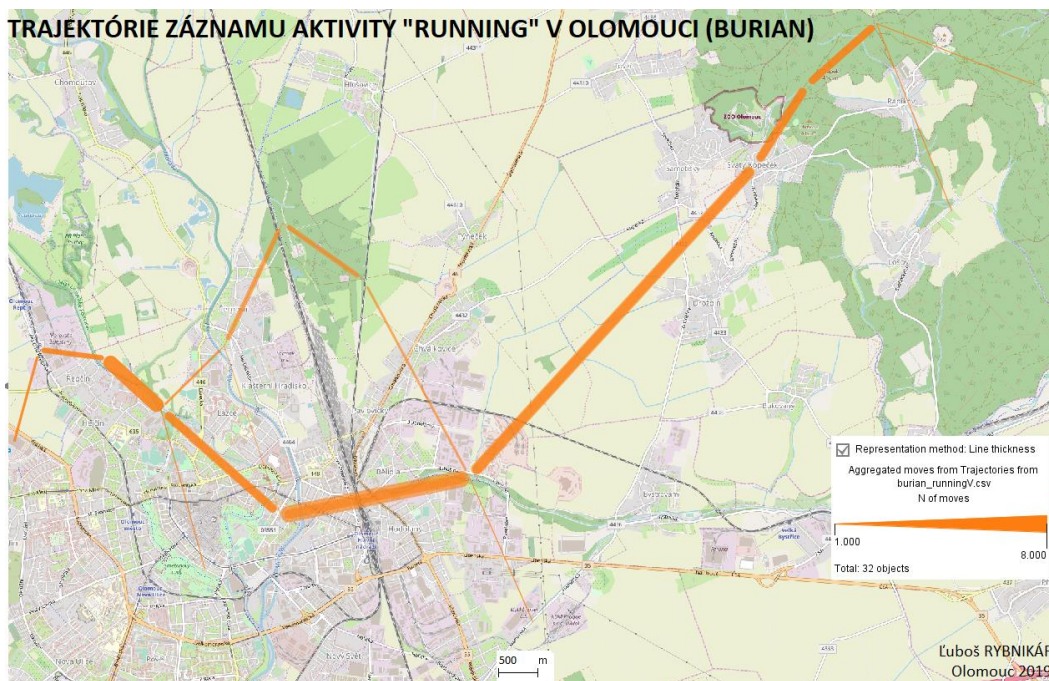
Príloha 5: Trajektórie záznamov aktivity v Olomouci



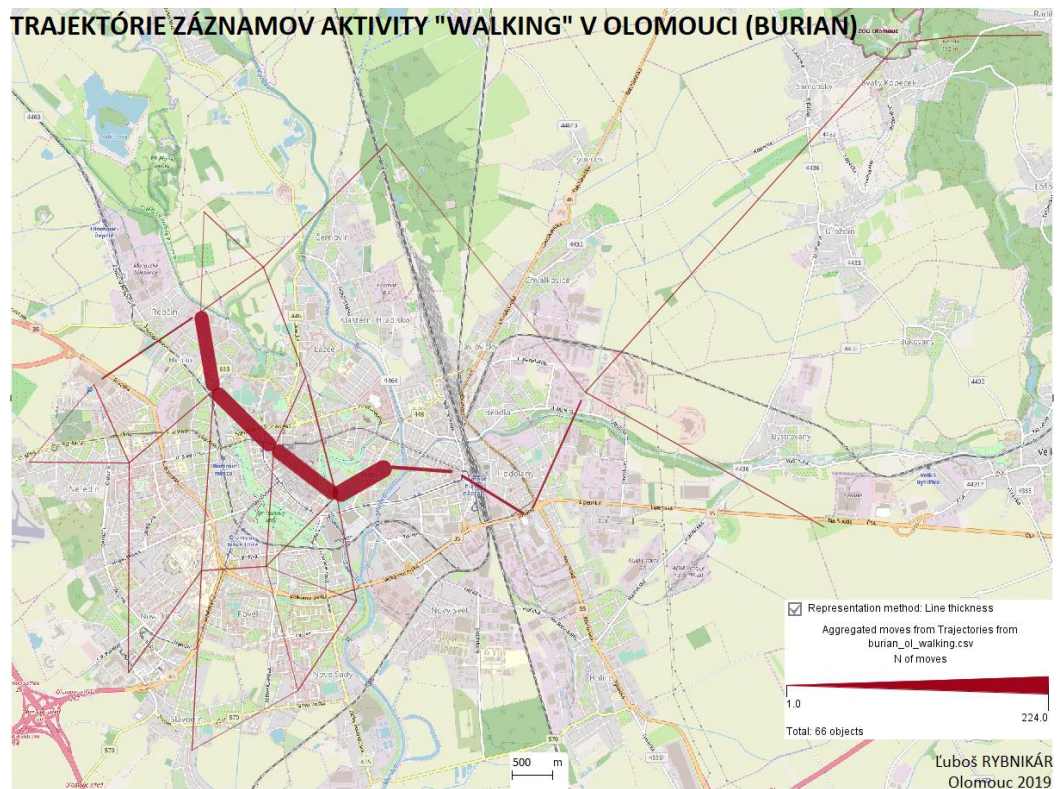
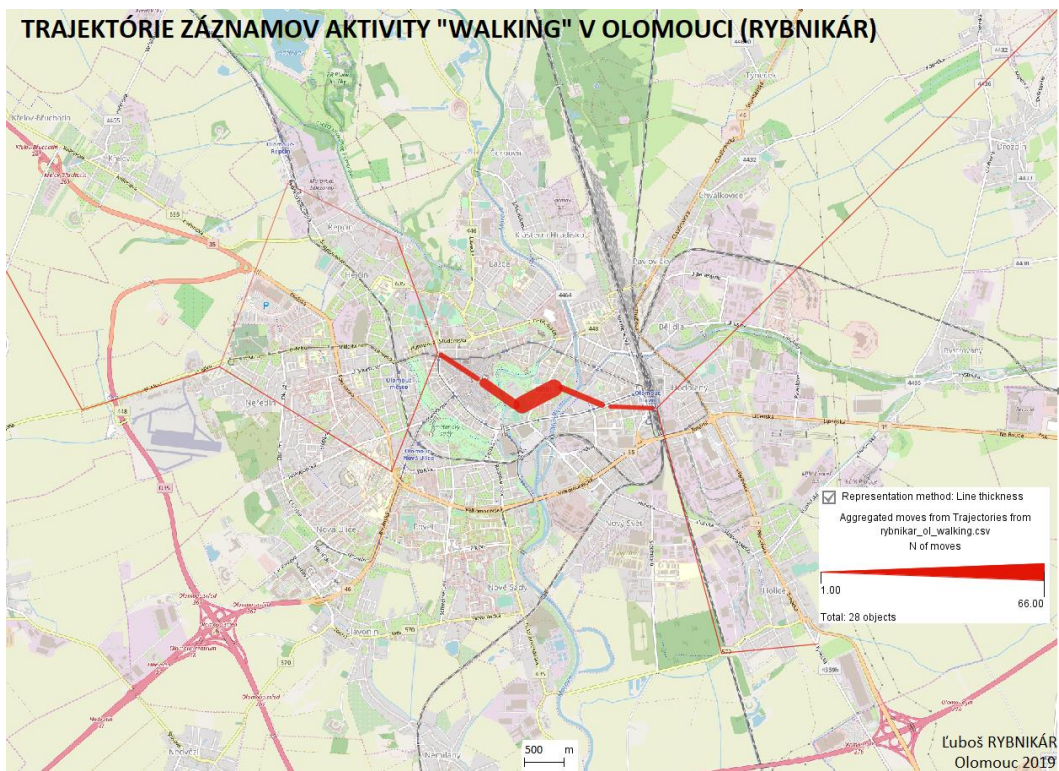
Príloha 5: Trajektórie záznamov aktivity v Olomouci



Príloha 5: Trajektórie záznamov aktivity v Olomouci



Príloha 5: Trajektórie záznamov aktivity v Olomouci



Príloha 5: Trajektórie záznamov aktivity v Olomouci

