

**Univerzita Palackého v Olomouci**

**Prírodovedecká fakulta**

**Katedra geoinformatiky**

**ANALÝZA PRIESTOROVÝCH VZOROV  
POHYBU VYBRANÝCH OSÔB V OLOMOUCI NA  
ZÁKLADE DÁT GOOGLE LOCATION**

**Diplomová práca**

**Bc. Ľuboš RYBNIKÁR**

**Vedúci práce doc. RNDr. Jaroslav BURIAN, PhD.**

**Olomouc 2021**

**Geoinformatika**

## **ANOTÁCIA**

Hlavným cieľom diplomovej práce je analyzovať zmeny priestorových vzorov pohybu vybraných osôb v Olomouci spôsobené pandemiou COVID-19 a obmedzeniami pohybu s ňou súvisiacimi s použitím dátových záznamov zo služby Google Location.

Teoretická časť práce obsahuje poznatky o definícii priestorového vzoru, analýze dát o pohybe osôb na základe dát z Google Location a iných zdrojov, analýze ľudskej mobility v mestskom prostredí a analýze zmien každodennej mobility osôb v dôsledku pandémie. Prehľad naštudovanej literatúry poskytuje tabuľka, ktorá je prílohou práce.

Praktická časť práce sa na začiatku zapodieva testovaním rôznych metód analýzy dát s dôrazom na zistené výhody a nevýhody použitia konkrétnych metód pri analýze dát z Google Location. Výhody a nevýhody testovaných metód sumarizuje prehľadová tabuľka. Niektoré z testovaných metód sú vybrané na použitie v prípadovej štúdii a ich výber je v texte práce zdôvodnený. Následne sa krátka časť práce venuje validácii dát z Google Location podľa dotazníkových dát, po čom nasleduje hlavná časť práce, ktorou je prípadová štúdia skúmajúca zmeny priestorových a časových vzorov pohybu vybraných osôb v Olomouci spôsobené pandemiou. Zmeny sú zisťované porovnávaním vizualizácii výsledkov analýz prevedených nad dátami z Google Location z dvoch časových období, pričom jedno obdobie je v roku 2019, teda pred prepuknutím pandémie a druhé v roku 2020 v jej priebehu. Zistením je, že u všetkých sledovaných osôb pandémie ovplyvnila každodennú mobilitu, ale u niektorých boli prítomné aj iné, s pandemiou nesúvisiace faktory, ktoré ovplyvnili ich najčastejšie trasy a miesta, v ktorých trávili najviac času.

## **KLÚČOVÉ SLOVÁ**

analýza; mobilita; Google Location; priestorový vzor; pandémia

Počet strán práce: 59

Počet príloh: 48 (z toho 25 viazaných, 23 voľných)

## **ANOTATION**

The main goal of this master thesis is to analyze changes of the spatial patterns of movement of selected persons in Olomouc caused by the COVID-19 pandemic and the restrictions connected to it using the data records from the Google Location service.

Theoretical part of the thesis contains knowledge about the spatial pattern definition, analysis of data about people's movement based on the data gained from Google Location and other sources, analysis of human mobility in the urban environment and analysis of changes in everyday human mobility caused by the pandemic. An overview of the studied literature is given in a table which is an attachment of this thesis.

Practical part of the thesis starts with testing of the various methods of data analysis with an emphasis on the found pros and cons of using the specific methods during the Google Location data analysis. The pros and cons of the tested methods are summarized in the attached table. Some of the tested methods are chosen to be used in a case study and this choice is justified in the text. Afterwards there is a short part of the thesis focusing on the validation of the Google Location data with data from the questionnaire. After that there is the main part of the thesis, a case study analyzing changes in the spatial and temporal patterns of movement of the selected persons in Olomouc caused by the pandemic. The changes are detected by comparing the visualizations from two time periods, whilst one period is in 2019 before the pandemic outbreak and another one is in 2020 during the pandemic. It is found out that the pandemic influenced the everyday mobility of all participants, but in some cases there were also other factors which influenced their most common routes and places where they spent most of the time that had nothing to do with the pandemic.

## **KEYWORDS**

analysis; mobility; Google Location; spatial pattern; pandemic

Number of pages: 59

Number of appendixes: 48 (25 tied, 23 free)

**Čestne prehlasujem, že**

- diplomovú prácu, vrátane príloh, som vypracoval samostatne a uviedol som všetky použité podklady a literatúru.

- som si vedomý, že na moju diplomovú 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, diplomovú prácu používať (§ 35 odst. 3),

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

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

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

- použiť výsledky a výstupy mojej diplomovej práce alebo poskytnúť licenciu k jej využitiu môžem len so súhlasom UP Olomouc, ktorá je oprávnená v takom prípade odo 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 doc. RNDr. Jaroslavovi Burianovi, Ph.D. za neustálu pomoc, cenné rady, návrhy na zlepšenie a pripomienky pri vypracovávaní práce. Ďalej ďakujem zamestnancom Katedry geoinformatiky za cenné rady pri konzultáciách a svojej rodine za neustálu psychickú podporu.

Za poskytnutie dát z Google Location pre účely spracovania v práci ďakujem študentom a zamestnancom Katedry geoinformatiky.

# UNIVERZITA PALACKÉHO V OLOMOUCI

Přírodovědecká fakulta

Akademický rok: 2019/2020

## ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Bc. Luboš RYBNÍKÁR**  
Osobní číslo: **R190625**  
Studijní program: **N1301 Geografie**  
Studijní obor: **Geoinformatika**  
Téma práce: **Analýza prostorových vzorů pohybu vybraných osob v Olomouci na základě dat Google Location**  
Zadávající katedra: **Katedra geoinformatiky**

### Zásady pro vypracování

Hlavním cílem diplomové práce je analyzovat prostorové vzory chování vybraných osob na území Olomouce (a okolí). Student nejprve osloví vybranou skupinu osob (např. studenti, zaměstnanci, dobrovolníci z řad občanů) a následně zorganizuje sběr dat o jejich pohybu prostřednictvím služby Google Location. Součástí sběru dat bude také dotazníkové šetření, jehož výsledky použije zejména pro validaci výstupů. Na základě sesbíraných dat zpracuje časoprostorovou analýzu, která bude sloužit zejména pro vyhodnocení (kvantifikaci, klasifikaci, typologii) prostorových vzorů pohybu. V případě potřeby bude sestaven nástroj (např. model nebo skript) umožňující automatizované zpracování dat. Výstupem práce budou vymezené prostorové vzory, data a vhodné mapové výstupy.

Celou práci, tj. text včetně všech příloh, posteru, výstupů, zdrojových i vytvořených dat, map, programových kódů a databází, student odevzdá v digitální podobě na paměťovém nosiči připevněném k deskám práce s popisem (jméno, název práce, Katedra geoinformatiky UP, rok). Text práce s přílohami odevzdá ve dvou svázaných výtiscích na sekretariát katedry ve stanoveném termínu. O práci student vytvoří webovou stránku v souladu s pravidly dostupnými na stránkách katedry. Práce bude zpracována podle obecných zásad (Voženilek, 2002) a závazné šablony pro kvalifikační práce na KGI. Povinnou přílohou práce je poster formátu A2.

Rozsah pracovní zprávy: **max. 50 stran**  
Rozsah grafických prací: **dle potřeby**  
Forma zpracování diplomové práce: **tištěná**  
Jazyk zpracování: **Slovenština**

### Seznam doporučené literatury:

Sablona KGI pro psaní bakalářských a magisterských prací

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

FRANTAL, Bohumil. 2012. Prostorové Chování: Vzorové Aktivit, Mobilita a Každodenní Život ve Meste. Masarykova univerzita.

GUDMUNDSSON, Joachim, Patrick LAUBE a Thomas WOLLE, 2017. Movement Patterns in Spatio-Temporal Data. In: Encyclopedia of GIS. B.m.: Springer International Publishing, s. 136271370.

HOU, Yuting a Adithi MOOGOR, 2019. Spatial analysis of older adults' travel behaviour in Singapore. In: Urban Environments for Healthy Ageing. B.m.: Routledge, s. 1177145.

IRWAN PADLI NASUTION, Muhammad a Samsudin SAMSUDIN, 2018. Using google location APIs to find an accurate criminal accident location. International Journal of Engineering & Technology. 7(3), 1818. ISSN 2227-524X.

KIM, Mi Kyeong, Sangpil KIM a Hong Gyoo SOHN, 2018. Relationship between Spatio-Temporal travel patterns derived from smart-card data and local environmental characteristics of Seoul, Korea. Sustainability (Switzerland). 10(3). ISSN 20711050.

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): 249-265.

LOCHTEFELD, Markus, 2019. Detournavigator – Using google location history to generate unfamiliar personal routes. Conference on Human Factors in Computing Systems – Proceedings. 176.

MACARULLA RODRIGUEZ, Andrea, Christian TIBERIUS, Roel VAN BREE a Zeno GERADTS, 2018. Google timeline accuracy assessment and error prediction. *Forensic Sciences Research*. B.m.: Taylor & Francis, 3(3), 240-255. ISSN 24711411.

NASERIAN, Elahe, Xinheng WANG, Keshav DAHAL, Zhi WANG a Zaijian WANG, 2018. Personalized location prediction for group travellers from spatial-temporal trajectories. *Future Generation Computer Systems*. 83, 278-292 [vid. 2018-04-30]. ISSN 0167739X.

POJSL, Lukas. 2014. "KAZDODENNI PROSTOROVA MOBILITA OBYVATEL VE MESTE STRAKONICE: VZORCE INDIVIDUALNI MOBILITY A JEJICH STUDIUM POMOCI MODERNICH GEINFORMACNICH TECHNOLOGII."

RUKTANONCHAI, Nick Warren, Corrine Warren RUKTANONCHAI, Jessica Rhona FLOYD a Andrew J. TATEM, 2018. Using Google Location History data to quantify fine-scale human mobility. *International Journal of Health Geographics*. B.m.: BioMed Central, 17(1), 1713. ISSN 1476072X.

ROMERO, Florencia Marina, 2019. Creation of images in virtual map location services. The case of Google Maps. *Hipertext.net: Revista Academica sobre Documentacion Digital y Comunicacion Interactiva*. 0(18), 66-76. ISSN 1695-5498.

SALOMON, Sergio, Cristina TIRNAUCA, Rafael DUQUE a Jose Luis MONTANA, 2017. Daily Routines Inference Based on Location History. s. 828-839 [vid. 2018-04-30].

SHARMEEN, Naila a Douglas HOUSTON, 2019. Spatial Characteristics and Activity Space Pattern Analysis of Dhaka City, Bangladesh. *Urban Science*. 3(1), 36. ISSN 2413-8851.

SOHN, Timothy, Alex VARSHAVSKY, Anthony LAMARCA, Mike Y. CHEN, Tanzeem CHOUDHURY, Ian SMITH, Sunny CONSOLVO, Jeffrey HIGHTOWER, William G. GRISWOLD a Eyal DE LARA, 2006. Mobility Detection Using Everyday GSM Traces. B.m.: Springer, Berlin, Heidelberg, s. 212-224 [vid. 2018-04-30].

WANG, Zhenzhen, Sylvia Y. HE a Yee LEUNG, 2018. Applying mobile phone data to travel behaviour research: A literature review. *Travel Behaviour and Society*. 11, 141-155 [vid. 2018-04-30]. ISSN 2214367X.

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

Datum zadání diplomové práce: **7. října 2019**  
Termín odevzdání diplomové práce: **6. května 2021**

L.S.

---

**doc. RNDr. Martin Kubala, Ph.D.**  
děkan



---

**prof. RNDr. Vít Voženílek, CSc.**  
vedoucí katedry

V Olomouci dne 7. září 2020

# OBSAH

ÚVOD .....	9
<b>1 CIELE PRÁCE.....</b>	<b>11</b>
<b>2 METÓDY A POSTUPY SPRACOVANIA.....</b>	<b>12</b>
2.1 Použité metódy .....	12
2.2 Použité dáta.....	13
2.3 Použité programy .....	13
2.4 Postup spracovania.....	13
<b>3 SÚČASNÝ STAV RIEŠENEJ PROBLEMATIKY .....</b>	<b>16</b>
3.1 Definícia priestorového vzoru .....	16
3.2 Analýza dát Google Location.....	17
3.3 Analýza ľudskej mobility v mestskom prostredí.....	19
3.3.1 Štúdie z Česka a Slovenska .....	19
3.3.2 Práce zahraničných autorov .....	22
3.4 Analýza obmedzenia mobility v dôsledku pandémie COVID-19 .....	23
<b>4 TESTOVANIE VYBRANÝCH METÓD ANALÝZY DÁT GOOGLE LOCATION .....</b>	<b>26</b>
4.1 Analýzy v ArcGIS Pro .....	26
4.1.1 Nástroj Aggregate Points.....	26
4.1.2 Výskyt v okolí vybraných bodov záujmu.....	28
4.1.3 Nástroj Calculate Density .....	29
4.1.4 Nástroj Collect Events .....	31
4.1.5 Nástroj Find Point Clusters .....	32
4.1.6 Nástroj Find Hot Spots .....	33
4.1.7 Nástroj Kernel Density .....	34
4.1.8 Space Time Cube .....	35
4.2 Časopriestorová animácia v QGIS.....	37
4.3 Kontingenčné tabuľky v MS Excel .....	39
4.4 Ďalšie spôsoby analýzy a vizualizácie dát.....	40
4.4.1 Location History Visualiser .....	40
4.4.2 Kepler GL.....	41
4.5 Zhodnotenie výhod a nevýhod použitých metód .....	43
<b>5 ANALÝZA DÁT VYBRANÝCH ŠTUDENTOV.....</b>	<b>44</b>
5.1 Porovnanie dát z Google Location s dotazníkovými dátami .....	44
5.2 Prípadová štúdia – analýza zmien priestorových vzorov pohybu študentov pôsobených pandemiou .....	45
5.2.1 Dáta Užívateľa 1.....	46
5.2.2 Dáta Užívateľa 2.....	47
5.2.3 Dáta Užívateľa 3.....	49
5.2.4 Dáta Užívateľa 4.....	51
5.2.5 Zhrnutie výsledkov prípadovej štúdie.....	52
<b>6 VÝSLEDKY .....</b>	<b>53</b>



6.1	Kartografické výstupy práce .....	53
6.2	Nekartografické výstupy práce.....	55
<b>7</b>	<b>DISKUSIA.....</b>	<b>56</b>
<b>8</b>	<b>ZÁVER .....</b>	<b>58</b>
	<b>POUŽITÁ LITERATÚRA A INFORMAČNÉ ZDROJE</b>	
	<b>PRÍLOHY</b>	

# ÚVOD

V čase pandémie COVID-19 sa ukázalo, aký veľký potenciál v sebe skrývajú dáta o pohybe osôb a aké dôležité pre nás môže byť vedieť ich správne analyzovať a tak získať informácie o ľudskej mobilite v časoch, keď by mal byť pohyb čo najviac obmedzený.

Jedným z cenných zdrojov dát o mobilite osôb, ich najčastejších trasách a najnavštevovanejších miestach môžu byť práve dáta Google Location. Autor už vo svojej bakalárskej práci testoval možnosti využitia dát tejto služby pre účely časopriestorových analýz pohybu osôb a zistil, že sa z nich po ich vhodnom predspracovaní a úprave dá zistiť veľké množstvo informácií o každodennej mobilite osôb. V diplomovej práci na svoj výskum nadväzuje a vzhľadom na vzniknutú pandemickú situáciu sa snaží zistiť, aké informácie o zmenách každodennej mobility osôb je možné získať z dát z Google Location.

Na začiatku práce sa autor zaoberá publikáciami a odbornými článkami, ktoré sa zaoberali problematikou aspoň čiastočne podobnou tejto diplomovej práci. K textu pridáva aj tabuľkový prehľad, ktorý má za cieľ sprehľadniť informácie o naštudovanej literatúre.

V praktickej časti práce autor na začiatku píše o metódach analýzy a vizualizácie dát v geografických informačných systémoch a v MS Excel, ktoré boli v práci otestované, spomína ich výhody a nevýhody, ktoré sú spísané aj v tabuľke a odôvodňuje, prečo vybral konkrétne metódy na spracovanie dát v prípadovej štúdií. Spomína aj ďalšie možnosti analýzy dát, nad ktorými uvažoval, ale v práci napokon neboli použité. Ďalej sa krátko venuje overovaniu poskytnutých dát podľa dotazníkových dát. Nasleduje najdôležitejšia časť práce – prípadová štúdia, v ktorej autor na základe výsledkov analýz prevedených pomocou vybraných metód zisťuje, ako veľmi zmenila pandémia priestorové vzory pohybu vybraných osôb v Olomouci. Na začiatku svojho výskumu vyslovuje predpoklad, že pandémia znížila celkovú mobilitu osôb a ovplyvnila ich výskyt v nimi predtým často navštevovaných miestach, čo sa mu s určitými výnimkami aj potvrdí.

Na konci práce autor vyhodnocuje získané výsledky, odôvodňuje, prečo sa mu niektoré pôvodne stanovené ciele nepodarilo naplniť a podáva krátku úvahu o tom, akým smerom by sa mohol uberať ďalší výskum v oblasti analýzy dát Google Location.

# 1 CIELE PRÁCE

Hlavným cieľom diplomovej práce je analyzovať priestorové vzory pohybu vybraných osôb v Olomouci s dôrazom na zmeny pred a po vypuknutí pandémie COVID-19. Vzhľadom na relatívne malé množstvo dát od malého počtu respondentov si autor dáva za cieľ klásť dôraz na vyskúšanie širokého spektra metód v rozličných geografických i negeografických softvéroch. Porovnaním výsledkov rôznych druhov metód bude zistené, ktoré metódy sú najvhodnejšie na účely spracovania dát zo služby Google Location a ich následnej vizualizácie. Získané dáta z Google Location budú tiež porovnané s dátami z dotazníkového šetrenia, čím bude overená presnosť určovania konkrétnych typov aktivity v týchto dátach.

Výstupom práce budú kartografické vizualizácie výsledkov analýz poskytnutých dát v geografických informačných systémoch vytvorené v súlade so všetkými platnými kartografickými pravidlami, ale taktiež tabuľky a grafy, ktoré budú výsledkom analýz v negeografických softvéroch. Výsledky tých analytických metód, ktoré budú určené ako najvhodnejšie, budú použité v prípadovej štúdií, ktorá bude sledovať zmeny najčastejšie navštívených lokalít a priestorových vzorov pohybu vybraných osôb v Olomouci vo vybraných obdobiach pred vypuknutím pandémie a v jej priebehu. Autor predpokladá, že pandémia ovplyvnila výskyt ľudí v škole, na pracovisku či v miestach trávenia voľného času a obmedzila aj celkovú mobilitu obyvateľstva. Tento predpoklad sa bude overovať na základe výsledkov prevedených analýz.

Výsledky práce umožnia zistiť, ako veľmi sa dá spoľahnúť na presnosť určovania typov aktivity v zázname z Google Location, aké metódy sú najvhodnejšie k analýze a vizualizácii dát služby Google Location a ako veľmi sa podľa dát z tejto služby zmenila mobilita vybraných osôb v Olomouci v dôsledku pandémie.

## 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 venujú kapitoly 4 a 5.

### 2.1 Použité metódy

Všetci respondenti, ktorí svoje dáta pre účely práce poskytli, si stiahli svoje dáta vo formáte JSON a poskytli ich autorovi práce. Analýze dát predchádzala predpríprava dát, ktorá bola založená na poznatkoch získaných počas písania bakalárskej práce Analýza a vizualizácia dát služby Google Location. Podrobnejšie informácie týkajúce sa tejto práce sú k dispozícii v podkapitole 3.2. Predpríprava pozostávala z konverzie dát z formátu JSON do formátu SHP, odfiltrovaní záznamov s nízkou presnosťou, určenia typu aktivity v tých záznamoch, v ktorých to bolo možné a časového a priestorového orezania dát. Konverzia dát do formátu SHP prebehla pomocou skriptu *read\_location\_data\_upgrade.py*, ktorý autor v roku 2019 stiahol z Githubu a mierne ho upravil (viac informácií v Rybníkar, 2019). Skript je k dispozícii na SD karte v zložke *Python*.

Záznam štyroch študentov katedry bol porovnávaný s dotazníkom vyplňaným od 23. do 29. 10. 2020. Respondenti – študenti mali za úlohu vyplňať ho v tomto období, skutočné časy vyplňovania dotazníka sa však od seba individuálne líšili.

Analýzy dát v ArcGIS Pro 2.6 zahŕňali použitie nástrojov *Aggregate Points*, *Buffer*, *Spatial Join*, *Calculate Density*, *Collect Events*, *Find Point Clusters*, *Find Hot Spots*, *Kernel Density*, *Create Space Time Cube by Aggregating Points a Visualize Space Time Cube in 3D*. Výsledky nástroja *Collect Events* boli upravené s použitím nástrojov *Buffer*, *Dissolve Boundaries*, *Spatial Join* a *Feature To Point*. V programe QGIS 3.18 boli vytvorené vizualizácie záznamov výskytu užívateľov v priebehu jednotlivých dní dvoch sledovaných období s pomocou pluginu *Temporal Controller*. V programe MS Excel 2016 boli z dát z dvoch sledovaných období vytvorené kontingenčné tabuľky, pomocou ktorých bolo skúmané časové rozloženie dát a početnosť vybraných typov aktivity. Z údajov z kontingenčných tabuliek boli vytvorené grafy, ktoré sú dostupné ako prílohy 2 – 5. Výhody a nevýhody použitia jednotlivých nástroj podrobnejšie popisuje kapitola 4.

Výsledky analýz boli vizualizované s použitím zásad, ktoré si autor osvojil v priebehu svojho päťročného štúdia. Výsledky všetkých analýz v programe ArcGIS Pro s výnimkou časopriestorovej kocky boli vizualizované formou máp vo formáte A3. Mapy pozostávajú zo šiestich mapových polí obsahujúcich výsledky analýz dát štyroch anonymných študentov označených ako Užívateľ 1–4, autora práce označeného ako Užívateľ 5 a zamestnanca katedry označeného ako Užívateľ 6. Výsledky nástroja *Visualize Space Time Cube in 3D* sú k dispozícii na SD v adresári *Projekty* v mapovom projekte *SpaceTimeCube.aprx*. Dôvody ponechať časopriestorové kocky vytvorené týmto nástrojom len v takejto forme sú podrobnejšie popísané v kapitole 4. Bolo rozhodnuté, že výsledky získané analýzou dát nástrojmi *Aggregate Points*, *Spatial Join*, kombináciou nástrojov *Buffer* a *Spatial Join*, *Kernel Density* a upraveného výsledku získaného z nástroja *Collect Events* majú dostatočnú výpovednú hodnotu na to, aby mohli byť použité v mapách porovnávajúcich dve sledované obdobia vytvorených v rámci prípadovej štúdie, ktorú podrobnejšie popisuje kapitola 5.

## 2.2 Použité dáta

Boli použité záznamy Google Histórie polohy autora práce, dáta zamestnanca Katedry geoinformatiky a štyroch študentov. Autorovi boli poskytnuté aj dáta zamestnancov Katedry geoinformatiky použité v prípadovej štúdií Pászto a kol., 2021, autor sa však nakoniec rozhodol sústrediť sa vo svojej práci primárne na analýzu dát študentov. Svoje dáta pre účely práce dodatočne poskytli aj ďalší dvaja študenti, tieto dáta boli však dosť nesúvislé a boli na nich síce vyskúšané niektoré analytické operácie, no pre účely práce nakoniec neboli použité. Z poskytnutých dát boli použité dáta s hodnotou atribútu Accuracy menšou alebo rovnou 100 z mesta Olomouc z dvoch časových období, konkrétne z času od 22. 10. do 22. 11. 2019 a od 22. 10. do 22. 11. 2020. V časových animáciách boli okrem bodov z územia mesta Olomouc použité aj body z jeho blízkeho okolia. Pri agregácii bodov na mestské časti boli použité dáta z ArcČR 500 v 3.3. Ako podkladová mapa vizualizácií vytvorených v programe ArcGIS Pro 2.6 bola použitá *World Topographic Map*, v programe QGIS bola použitá *Prehľadacia služba WMS ZM 10* od ČÚZK.

## 2.3 Použité programy

Konverzia dát z formátu JSON do formátu GeoJSON prebehla v príkazovom riadku, z formátu GeoJSON do formátu SHP a v programe QGIS Desktop 3.18.1. Prevažná časť dátovej analýzy bola prevedená v programe ArcGIS Pro, verzia 2.6. Počiatočné spracovanie dát autora práce a štyroch študentov Katedry geoinformatiky prebehla v programe ArcGIS for Desktop 10.6. Časové animácie boli vytvorené s použitím programu QGIS Desktop 3.18 a webového nástroja Animated GIF Maker. Študenti, ktorí svoje dáta pre účely analýzy svoje dáta poskytli, vyplňali dotazník v Google Tabuľkách, pričom tento dotazník bol následne stiahnutý a komentár autora bol pridaný v programe MS Excel 2016. Kontingenčné tabuľky a grafy boli taktiež vytvorené v programe MS Excel 2016 a v tomto programe bol vytvorený aj tabuľkový prehľad existujúcich štúdií a tabuľkový prehľad metód analýzy dát. Diagram znázorňujúci postup práce a poster k diplomovej práci boli vytvorené v programe Adobe Illustrator 2021. Webové stránky práce boli vytvorené s použitím šablóny od TEMPLATE.

## 2.4 Postup spracovania

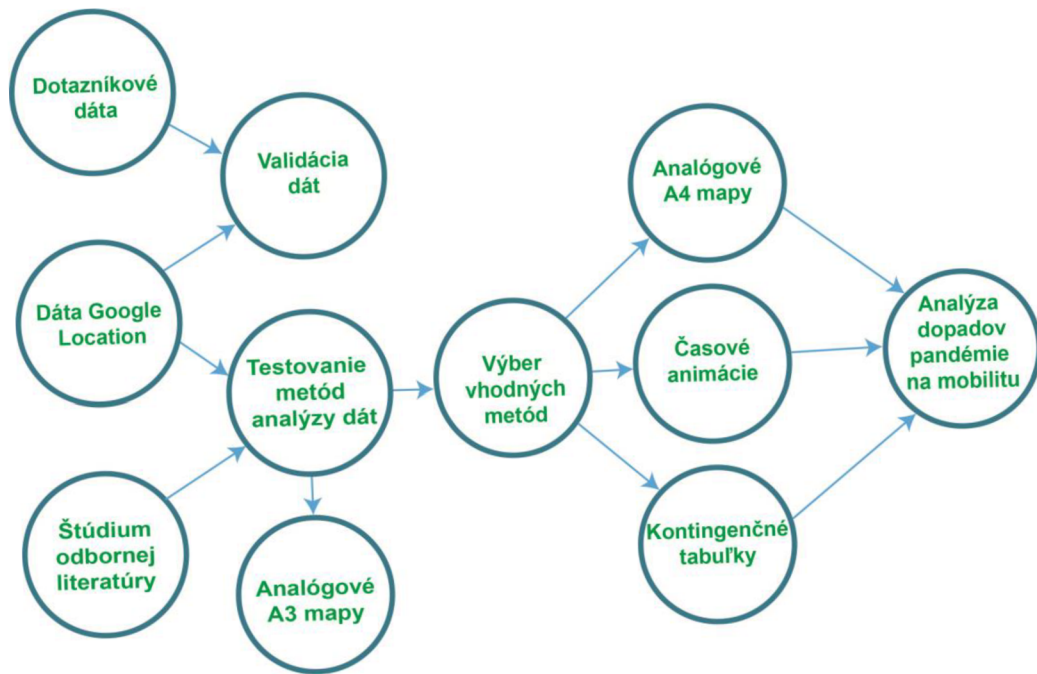
Samotnému zberu a spracovaniu dát predchádzalo štúdium literatúry zaoberajúcej sa najmä analýzou priestorových vzorov pohybu osôb s použitím rôznych zdrojov dát vrátane dát Google Location, analýzou samotného záznamu z Google Location a analýzou zmien ľudskej mobility spôsobených pandemiou. Autor vychádzal z poznatkov získaných pri písaní bakalárskej práce, ktoré si štúdiom novej literatúry ďalej rozširoval. Pre lepší prehľad o súvislostiach medzi preštudovanou literatúrou a zameraním práce vytvoril autor tabuľkový prehľad existujúcich štúdií (Príloha 34).

Celý proces spracovania práce bol do značnej miery ovplyvnený pandemiou COVID-19. Pôvodne bol v pláne dvojmesačný výskum mobility v rámci Olomouca v spolupráci s Magistrátom mesta Olomouc. V rámci tohto výskumu mali užívatelia, ktorí by sa doňho zapojili, získať bezplatné kombinované lístky na MHD a Rekola a výskum mal viesť k zisteniu opodstatnenosti takýchto lístkov. Účastníci mali mať po celú dobu výskumu zapnuté zaznamenávanie Google histórie polohy a súčasne vyplňať dotazník o typoch svojej pohybovej aktivity v rámci mesta Olomouc v priebehu dňa. Cieľom tejto prípadovej štúdie mala byť jednak validácia dát z Google Location s dotazníkovými dátami a súčasne aj zistenie, ako veľmi kombinované lístky na MHD a Rekola ovplyvnia

mobilitu užívateľov. So zberom dát bolo plánované začať v druhej polovici marca 2020 a mal trvať do druhej polovice mája. Práve v druhej polovici marca 2020 však prepukla pandémia a z toho dôvodu bolo potrebné vymyslieť nový, alternatívny plán. Pôvodne sa uvažovalo nad zberom dát v letných mesiacoch po zrušení väčšiny opatrení, problémom však bolo, že v tom čase sa v Olomouci nachádzalo podstatne menšie množstvo študentov. Nakoniec sa s hľadaním respondentov začalo až v októbri 2020, krátko predtým, než bola na Univerzite Palackého celoplošne zavedená dištančná výuka. Email so žiadosťou o zapojenie sa do výskumu, ktorý bude súčasťou diplomovej práce, bol zaslaný študentov všetkých ročníkov Katedry geoinformatiky, ale práve z toho dôvodu, že väčšina študentov sa pri zavedení dištančnej výuky vrátila z Olomouca domov, sa našli len štyria ľudia ochotní poskytnúť svoje dáta a zapojiť sa do výskumu.

So študentami, ktorí sa zapojili, bol termín zberu dát dohodnutý na 22. 10. – 22. 11. s tým, že v priebehu prvého týždňa zberu dát budú vyplňať v dotazníku svoje každodenné pohybové aktivity, ktoré budú v Olomouci vykonávať. Po skončení tohto obdobia si študenti svoje dáta z Google Location stiahli a poslali ich autorovi na mail. Po získaní dát nasledovalo najprv ich počiatočné predspracovanie, ktoré bolo zrealizované na základe znalostí získaných pri tvorbe bakalárskej práce. Po ňom nasledovalo porovnanie dát s dotazníkovými dátami. Nasledovala prezentácia v rámci 2. magisterského dňa, ktorá motivovala zamestnanca katedry a dvoch ďalších študentov k poskytnutiu dát pre účely práce. Následne vedúci práce poskytol dáta seba a troch zamestnancov katedry spolu s výsledkami analýz nad týmito dátami, ktoré boli použité v prípadovej štúdií Pászto a kol., 2021. Tieto dáta napokon neboli v rámci práce ďalej spracované, spomínaná štúdia však poslúžila ako inšpirácia k použitiu niektorých nástrojov analýzy dát a k myšlienke porovnania dát z obdobia pred pandémiou a v jej priebehu. V nasledujúcom období sa autor venoval testovaniu rozličných metód analýzy dát v ArcGIS Pro. V marci 2021 mal autor konzultácie s ľuďmi, ktorí mu poskytli dáta a ukazoval im výsledky svojich analýz nad ich dátami a spolu s nimi sa snažil tieto výsledky interpretovať. Tieto konzultácie boli do značnej miery smerodajné pre ďalší postup práce a pomohli autorovi vybrať metódy vhodné pre spracovanie dát v rámci prípadovej štúdie. Následne sa začal autor venovať aj vytváraniu kontingenčných tabuliek v programe MS Excel a animácií v programe QGIS.

Nasledovala fáza vizualizácie vybraných výsledkov analýz prevádzaných nad dátami. V tejto fáze sa rozhodlo o tom, že výsledky analýz všetkými druhmi nástrojov v programe ArcGIS Pro s výnimkou *Space Time Cube* budú vizualizované vo forme máp vo formáte A3 a budú to výsledky nie za časové obdobie, na ktoré sa práca mala sústrediť, ale za obdobie rok predtým, teda od 22. 10. do 22. 11. 2019. Výsledky analýz, ktoré mali dostatočnú výpovednú hodnotu, boli vizualizované aj formou máp vo formáte A4 porovnávajúcich mobilitu užívateľov v období pred pandémiou v roku 2019 a v období v priebehu pandémie v roku 2020. Podobným spôsobom boli porovnané aj výsledky z dvoch sledovaných období z kontingenčných tabuliek a z animovaných máp z programu QGIS. Proces rozhodovania o použití výsledkov analýz pre účely analýzy priestorových vzorov je popísaný v kapitole 4, interpretácii výsledkov v rámci prípadovej štúdie sa venuje kapitola 5 a popisu výsledkov kapitola 6. Priebežné výsledky práce boli pravidelne konzultované s osobami, ktoré pre jej účely svoje dáta poskytli, bola im ukázaná aj finálna podoba vizualizácií a rovnako s nimi bola konzultovaná aj interpretácia výsledkov, do ktorej boli doplnené ich postrehy. Postupnosť a nadväznosť jednotlivých krokov vypracovania diplomovej práce znázorňuje vývojový diagram (Obr. 2.1).



Obr. 2.1 – Diagram znázorňujúci postup pri tvorbe diplomovej práce

### 3 SÚČASNÝ STAV RIEŠENEJ PROBLEMATIKY

Zberu dát o polohe osôb rozličnými spôsobmi sa venovalo už široké spektrum autorov a rovnako sa už veľké množstvo štúdií venovalo aj rozličným metódam analýzy priestorových vzorov pohybu osôb. V tejto kapitole sú spomenuté tie z nich, ktoré mali pre prácu zásadný význam. V tabuľkovom prehľade (Príloha 6) sú uvedené okrem nich aj ďalšie práce, ktoré mali s touto diplomovou prácou nejakú súvislosť.

#### 3.1 Definícia priestorového vzoru

Keďže cieľom tejto diplomovej práce je analyzovať časopriestorové vzory pohybu osôb, je určite na mieste podať na začiatku definíciu toho, čím vlastne priestorový vzor je. Prečítané práce prispeli k lepšiemu pochopeniu problematiky vzorov v geoinformatike a vo vizuálnej analytike a vytvoreniu vlastnej definície priestorového vzoru použitej v tejto práci.

Veľký význam pre účely tejto diplomovej práce, má práca Andrienko a kol., 2021 zaoberajúca sa definíciou vzoru vo vizuálnej analýze. Práca navrhuje možnú definíciu konceptu vzoru v rozdelení dát ako kombináciu viacnásobne prepojených prvkov dvoch alebo viacerých dátových komponentov, ktoré môžu byť považované za zjednotený celok. Teoretický model popisuje vytváranie vzorov na základe vzťahov existujúcich medzi dátovými prvkami. Model tiež navrhuje celý rad interaktívnych analytických operácií podporujúcich pracovné postupy vizuálnej analýzy, v ktorých sú vzory po svojom objavení zahrnuté v ďalšej dátovej analýze. Podstata modelu je zhrnutá v niekoľkých výrokoch: Vzor pozostáva zo vzťahov medzi viacerými prvkami aspoň dvoch zložiek dát, je kombináciou vzťahov umožňujúcou viacerým prvkom, aby boli vnímané a/alebo reprezentované holisticky ako jeden objekt. Typy vzorov sú určené typmi vzťahov medzi zložkami dát. Za účelom objavenia vzorov analytici skúmajú rozloženie prvkov jednej alebo viacerých zložiek prihliadajúc k prvkom inej zložky a vzťahom medzi týmito prvkami. Analytici môžu využiť objavené vzory v ďalších krokoch analýzy dát použitím analytických operácií. V práci sa tiež spomínajú rozličné definície vzorov v matematike, štatistike, geografických vedách, teórii informácie, data miningu a vo vizuálnej analýze. Ako podstatné pre túto prácu sa javí byť poňatie vzorov v geografických vedách, v ktorých sú definované ako usporiadanie individuálnych entít v priestore a geografických vzťahov medzi nimi, z čoho vychádza aj definícia priestorového vzoru použitá v tejto práci. Priestorové vzory sú charakterizované špecifickými metrikami koncentrácie, rozptylu, náhodnosti a zhľukovania. Dôležitá je priestorová autokorelácia, ktorá indikuje, ako je objekt ovplyvňovaný podobnými objektami vo svojom okolí. V poňatí vzorov vo vizualizácii a vizuálnej analytike sa píše, že dátové vzory sú vytvárané vzťahmi medzi dátovými prvkami a vizuálne reprezentácie môžu odhaliť vzory existujúce v dátach, keď znaky reprezentujúce dátové prvky zodpovedajú vzťahom medzi dátovými prvkami. V práci sú rozlišované 3 typy vzorov, a to kompozičné vzory, vzory usporiadania a vzory variácií. Usporiadanie dát môže byť lineárne, ale dáta môžu byť usporiadané aj do denných, týždenných a sezónnych cyklov. Vzťahy medzi vzormi môžu zahŕňať podobnosť, obsiahnutie, opakovanie a vzájomné prekrývanie. Základné analytické operácie so vzormi zahŕňajú operácie s vnútorným obsahom jednotlivých vzorov, porovnávanie obsahu niekoľkých vzorov, operácie so vzťahmi medzi vzormi a operácie využívajúce vzťahy medzi prvkami vzorov. V práci sú odlišené dva prístupy k nachádzaniu vzorov – vizuálny a výpočtový. Aby bolo možné nájsť vzory vo vizuálnej reprezentácii, musia byť v nej verne ukázané existujúce vzťahy, nesmú sa z nej dať



vyčítať vzťahy, ktoré neexistujú a malo by v nej dochádzať k percepčnému zjednoteniu viacerých prvkov.

Podľa Godmundssona a kol. 2017, sú časopriestorové dáta akékoľvek dáta týkajúce sa priestoru a času. Priestorové vzory pohybu v takýchto dátach označujú hlavné udalosti a epizódy vyjadrené súborom entít. Za priestorový vzor môže byť v kontexte dopravy považovaná aj zápcha. U zvierat môže byť za priestorový vzor považované stádo oviec alebo krdel vtákov. Iba formalizované vzory môžu byť detegované pomocou algoritmov. Vzory sú modelované ako akékoľvek usporiadanie subtrajektórií, ktoré je možné dostatočne definovať a formalizovať. Z historického hľadiska sa dá analýza priestorových vzorov považovať za relatívne mladú a málo rozvinutú oblasť výskumu. Prostredníctvom GPS a iných technológií slúžiacich ku sledovaniu sa výskum dostal do novej éry, v ktorej je možné nízko nákladové, takmer nepretržité snímanie jednotlivých trajektórií s možnými sekundárnymi vzorkovacími rýchlosťami. V geoinformatike je termín vzor používaný v rôznych súvislostiach a významoch súvisiacich s pohybom. Priestorové vzory sú všeobecne konceptualizované ako najvýznamnejšie pohybové udalosti alebo epizódy v priestorovej reprezentácii pohybujúcich sa entít. Hlavné pohybové vzorce môžu byť získané z dvojrozmerných máp trajektórií, animovaných máp alebo z trojrozmerných reprezentácií pohybu, v ktorých je tretím rozmerom čas. Najčastejšími dotazmi pri indexovaní časopriestorových trajektórií sú dotazy na časopriestorový rozsah, na najbližších priestorových susedov podľa časového intervalu a najbližších časových susedov podľa priestorového regiónu. Z metód indexovania poznáme *Parametric Space indexing methods* a *Native Space Indexing Methods*. Spomedzi algoritmov sa používa Association rule mining hľadajúci asociácie medzi transakciami v relačných databázach. Pri algoritme STARS (*Spatiotemporal Association Rules*) je priestor rozdelený na regióny o ľubovoľnej veľkosti a cieľom je nájsť „zaujímavé“ regióny a pravidlá predikujúce pohyb entít medzi regiónmi. Región je považovaný za zaujímavý, keď doňho veľký počet entít prichádza a z neho odchádza. Za periodické vzory môže byť považovaná každoročná migrácia zvierat alebo každodenné dochádzanie ľudí. Pri tzv. vodcovských vzoroch je definovaný vodca entity, ktorý nikoho ďalšieho nesleduje, je nasledovaný súborom entít a toto správanie pretrváva určitý čas.

Na základe prečítanej literatúry si autor stanovil **definíciu priestorového vzoru** ako súboru miest, v ktorých strávil užívateľ najviac času a trás medzi týmito miestami, po ktorých sa najčastejšie presúval.

### 3.2 Analýza dát Google Location

Potenciál dát Google Location ešte nebol naplno využitý a ich analýze sa zatiaľ venovalo len malé množstvo autorov. Výhodou týchto dát je, že k ich zberu nie sú potrebné žiadne špeciálne zariadenia, nevýhodou však ostáva otázka súkromia a s ňou spojená neochota ľudí poskytnúť tieto dáta na študijné účely.

Autor práce v roku 2019 vo svojej bakalárskej práci hľadal možnosti využitia dát služby Google Location pre časopriestorové analýzy pohybu osôb. Dáta o histórii polohy si stiahol vo formáte JSON. Geografické informačné systémy neposkytujú možnosť zobrazenia dát v tomto formáte ani ich konverziu a aj preto bola konverzia dát v jeho práci realizovaná pomocou skriptu `read_location_data.py` získaného zo stránky [https://github.com/iboates/android\\_location\\_converter](https://github.com/iboates/android_location_converter). Pôvodný skript nekonvertoval záznamy pre všetky typy aktivity, preto musel byť upravený. Skript umožňuje konverziu do formátov SHP, KML a GEOJSON, ale pri konverzii do formátu SHP

dochádza ku strate časti dát, preto boli dáta konvertované do formátu GEOJSON a až potom v programe QGIS do formátu SHP. Ďalej sa autor vo svojej práci venoval hľadaniu takých záznamov, ktoré budú použiteľné pre ďalšiu prácu. Zistil, že vhodná hraničná hodnota *Accuracy* je 100 a vhodná hraničná hodnota pravdepodobnosti jednotlivých aktivít je 50. Dáta boli v práci štatisticky analyzované v programoch MS Excel a RStudio za účelom lepšie pochopiť význam jednotlivých atribútov dát a ich hodnôt. V práci boli tiež vytvorené kartografické vizualizácie dát. V programe ArcGIS boli vytvorené mapy intenzity výskytu užívateľov s použitím nástroja Kernel Density, v ArcGIS Online boli vytvorené mapy intenzity výskytu užívateľov a časové animácie agregovaných bodových záznamov výskytu a v programe V-Analytics boli vytvorené vizualizácie trajektórií pohybu. Hlavným výsledkom práce bolo zistenie, že dáta Google Location môžu byť použité pre účely časopriestorových analýz pohybu osôb.

Löchtfeld, 2019, predstavil vo svojej práci Detour Navigator, navigačnú službu vytvárajúcu personalizované trasy pre užívateľov na základe ich História polohy v oblastiach, ktoré pre nich nie sú známe. Detour Navigator by mal užívateľom umožniť objaviť viac častí mesta a vybudovať si celistvejší prehľad o častiach mesta. V práci sa pracovalo s bodmi s hodnotou atribútu *Accuracy* nižšou než 50, bol teda stanovený nižší limit, než si ho stanovil vo svojej práci Rybnikár, 2019. Pre všetky skupiny počiatočných a koncových bodov bola v práci vypočítaná najkratšia trasa a trasa, ktorú užívateľ s vysokou pravdepodobnosťou nepozná. Za účelom otestovania aplikácie bola prevedená predbežná užívateľská štúdia meste Aalborg v Dánsku s deviatimi účastníkmi vo veku od 21 do 28 rokov. V prvej časti experimentu boli vytvorené dve trasy z jedného počiatočného do dvoch koncových bodov. Na ich vytvorenie boli použité Normal Graph a Detour Graph. Experimentátor bol v jej priebehu s respondentmi a pýtal sa ich, ako dobre poznajú danú trasu. V druhej časti bolo vytvorených 10 ďalších trás, z čoho 5 bolo vytvorených v Detour Graph a 5 v Normal Graph, pracovalo sa s fotografiami zo Street View a užívatelia mali uviesť, ako veľmi trasu poznajú. Po tejto časti nasledoval rozhovor, v ktorom sa experimentátor pýtal užívateľov na ich dojmy. V štúdiu sa potvrdilo, že Detour Graph vytvára trasy, ktoré sú pre užívateľov menej známe. Potvrdil sa predpoklad, že používanie Google História polohy by mohlo byť dobrým dátovým zdrojom na vyhodnotenie znalosti mestského prostredia. Nevýhodou štúdie bolo, že prebiehala len v jednom meste a preto nemá dostatočnú výpovednú hodnotu.

Rodriguez a kol. 2018, sa v práci snažili vyčíslíť chybu dát Google Location a vyvinúť model, ktorý by dokázal predpovedať odchýlku s ohľadom na skutočnú polohu užívateľa. Premenné s potenciálnym vplyvom na určenie polohy užívateľa boli v štúdiu skúmané z toho dôvodu, že Google neposkytuje informácie o algoritmoch výpočtu odhadu polohy a parametroch do výpočtu vstupujúcich. V práci bol použitý multilineárny regresný model za účelom určenia vzťahu medzi premennými prostredia a presnosťou a chybou očakávanými spoločnosťou Google. V experimentoch sa bral do úvahy dátum a čas, konfigurácia telefónu, mestské a vidiecke prostredie, počasie, intenzita dopravy a použitý dopravný prostriedok. Každý experiment mal jednotný postup a pozostával z časovej synchronizácie, konfigurácie systému, stanovenia podmienok experimentu, logcat registrácie, ukončenia experimentu a spracovania dát v prostredí Matlab. Zistením z experimentov bolo, že počasie a intenzita dopravy neovplyvňujú presnosť určenia polohy, ale vo vidieckom prostredí boli hodnoty *Accuracy* vyššie než mestskom. V práci sú tiež predstavené pojmy Google Hit a Google Miss. Google Hit znamená, že polohu sa podarilo určiť s dostatočnou presnosťou, zatiaľ čo

Google Miss znamená, že presnosť nie je dostatočná a hodnota chyby je väčšia, než stanovená hraničná hodnota *Accuracy*.

Ruktanonchai a kol. , 2018, vo svojej štúdiu validovali dáta z Google histórie polohy s dátami z GPS prijímača od užívateľov OS Android v Spojenom kráľovstve. Cieľom pilotnej štúdie bolo zistiť, aká veľká časť používateľov Androidu má aktivovanú históriu polohy a možná korelácia s využívaním Google služieb, ďalej sa tiež skúmala závislosť zaznamenávania histórie polohy na mobilnom signáli a priestorová presnosť bodov z Google Location v porovnaní s GPS sledovacími jednotkami. Do výskumu sa zapojilo 26 ľudí z University of Southampton v čase od októbra do decembra 2016. Účastníci výskumu boli rozdelení do dvoch skupín, pričom v jednej skupine boli informácie o pohybe zaznamenávané len prostredníctvom Google Location, zatiaľ čo v druhej súčasne aj pomocou GPS prijímača. Zistením z práce bolo, že dáta z Google Location sú podobné dátam z GPS, ale ich zber je jednoduchší a je možný aj zber dát za veľmi dlhé časové obdobia.

### **3.3 Analýza ľudskej mobility v mestskom prostredí**

Výskum každodennej ľudskej mobility v mestskom prostredí môže poskytnúť cenné informácie pre mestské samosprávy, ktoré ich môžu ďalej použiť napríklad pre účely územného plánovania alebo plánovania dopravy. Dnešná doba nám ponúka široké spektrum možností, ako je možné takéto dáta získať a na nasledujúcich stranách je uvedených niekoľko príkladov z Česka, Slovenska a iných krajín.

#### **3.3.1 Štúdie z Česka a Slovenska**

Vondráková, 2007, sa vo svojej bakalárskej práci venovala sledovaniu pohybu osôb v Olomouci v troch lokalitách, konkrétne na sídlisku Černá cesta, na Hornom námestí a OC Haná. Dáta boli zbierané formou pozorovania a dotazníkového šetrenia. Ako sekundárny zdroj dát boli použité 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). Získané údaje boli štatisticky vyhodnocované a kartograficky spracované pomocou bodovo lokalizovaných diagramov a interpolácie.

Frantál, 2012, sa zapodieval 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 a predstavil niektoré typické príklady geovizualizácie 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 vyplňaných 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, porovnávali 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 vizualizovaný pomocou softvéru V-Analytics. Bolo zistené, že pomocou časového vzorca správania populácie je možné identifikovať širokú škálu informácií.

Pojsl, 2014, sa snažil zmapovať každodennú priestorovú mobilitu v prostredí mesta Strakonice. Počas výskumu analyzoval dáta získané dotazníkovým šetrením a záznamy vytvorené GPS lokátormi. Obe metódy boli do výskumu zapojené súbežne. Stanovil predpoklad, že pravidelné cesty zahŕňajúce dochádzky do práce a do školy budú zahŕňať 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.

Zdēradička, 2016, píše o pilotnom projekte získania dát o priestorovom správaní obyvateľov hl. mesta Prahy a Stredočeského kraja na báze dát mobilného operátora realizovanom v roku 2015 Inštitútom plánovania a rozvoje hlavného mesta Prahy v spolupráci s TSK, ROPID, DP Praha PIS a Městskou knihovnou. Dodávateľom dát bola spoločnosť O2. Údaje z monitoringu rozmiestnenia a mobility obyvateľstva sú kľúčové pre plán udržateľnej mobility hlavného mesta Prahy, územne analytické podklady, plán historického centra Prahy a ďalej môžu byť použité napríklad aj na monitoring pohybu turistov v centre Prahy. Sledovanými údajmi v rámci projektu sú počty rezidentov, pracujúcich, návštevníkov a tranzitujúcich v základných sídelných jednotkách v Prahe a v Stredočeskom kraji v typický pracovný deň a v sobotu a ďalej v hodinových rezoch typického pracovného dňa a soboty. Pracuje sa s maticou zdrojov a cieľov dennej dochádzky za prácou v rámci Prahy a Stredočeského kraja a maticou zdrojov a cieľov dennej dochádzky návštevníkov kratších pobytov v rámci Prahy a Stredočeského kraja. Výstupy projektu potvrdzujú vysoký potenciál využitia pre agendu mesta a mestské organizácie.

Novák, 2012, vo svojej pilotnej štúdií využitia lokalizačných dát mobilných telefónov skúmal každodenný život a priestorovú mobilitu mladých Pražanov. Cieľom jeho štúdie bolo zistiť potenciál dát o polohe získaných z mobilných telefónov v geografickom výskume každodenného života a individuálnej priestorovej mobility populácie. Každý človek si podľa neho vytvára svoj časopriestorový podpis, súčasťou ktorého sú navštívené miesta a ich chronologické usporiadanie. V štúdií sú predstavené základné axiomy geografie času, podľa ktorých majú ľudské bytosti nedeliteľnú podstatu, priestor má obmedzené kapacity pre realizáciu fyzických udalostí, každá existencia je časovo obmedzená, realizácia každej činnosti vyžaduje určitý čas, každý priestorový presun vyžaduje určitý čas, možnosť človeka podieľať sa na viacerých činnostiach v jednom okamihu je obmedzená a každý objekt má svoju časopriestorovú históriu. Kľúčovými stanicami z pohľadu každodenného života sú domov a pracovisko. Zámerom pilotnej

štúdie bolo skĺbiť pozitíva riadených rozhovorov a presných záznamov časopriestorových trajektórií za dobu jedného týždňa. Trajektórie boli zaznamenávané pomocou zariadenia SS7 tracker zisťujúceho polohu mobilného telefónu pomocou identifikačných údajov jednotlivých BTS. Respondentami bolo 50 mladých obyvateľov Prahy vo veku do 40 rokov. Rozhovory, pri ktorých sa pracovalo so záznamom trajektórií pohybu, boli prevedené len s dvadsiatimi účastníkmi. Z denných trajektórií pohybu boli extrahované informácie o počte navštívených staníc, teda miest, v ktorých respondenti strávili viac než 30 minút, o celkovej dĺžke uskutočnených presunov, čase strávenom v jednotlivých staniaciach a maximálnej vzdialenosti stanice od primárnej stanice. Pri identifikácii štýlov mobility boli za štýlotvorné prvky považované počet staníc, rutinnosť či variabilita priestorových vzorov, rozsah priestorových pohybov z hľadiska vzdialenosti a času a charakter navštívených staníc a povaha v nich realizovaných aktivít. Na základe toho boli vymedzené štýly priestorovej mobility. Aktívny štýl priestorovej mobility, ktorý ďalej môžeme rozdeliť na aktívny štýl sýtený prácou a aktívny štýl sýtený zábavou a ďalej pasívny štýl priestorovej mobility, ktorý môže byť spojený so starostlivosťou o dieťa alebo s nedeľnou dochádzkou.

Soukup, 2017, sa vo svojom článku zapodieval otázkou, čo nám môžu prezradiť dáta z mobilov. Takéto dáta môžu mať podľa neho využitie v územnom a dopravnom plánovaní, krízovom riadení a plánovaní, cestovnom ruchu a plánovaní služieb. Pracoval s dátami s podrobnosťou na ZSJ na území Prahy a Stredočeského kraja a s podrobnosťou na okresy vo zvyšku Českej republiky. Obyvateľov klasifikoval na rezidentov, pracujúcich, návštevníkov a tranzitujúcich. Štúdia prebiehala 5 týždňov v októbri a novembri roku 2015. Pracovalo sa s celkovým denným a hodinovým počtom prítomného obyvateľstva v územných jednotkách a počtom pravidelne dochádzajúcich medzi územnými jednotkami. Dáta boli importované do Oracle SDE databázy, kde boli vytvorené pohľady umožňujúce prepojenie s priestorovým vymedzením a tým ľahký prístup prostredníctvom programu ArcGIS. Nad dátami bola vytvorená webová aplikácia umožňujúca preskúmanie týchto dát priamo z webového prehliadača, zobrazujúca celkové denné stavy, časové výrezy a dochádzkové vzťahy. Bolo zistené, že v noci je najväčšia hustota obyvateľstva v rezidenčných oblastiach, zatiaľ čo cez deň tam zostáva približne len polovica z nočného stavu, pričom najvýraznejšie je denné vyľudnenie obcí v okolí Prahy. Za určité limity práce sa dá považovať to, že dáta boli získané len od jedného mobilného operátora a reprezentatívnosť vzorky je tým pádom diskutabilná, a súčasne aj to, že hranice základných sídelných jednotiek sú odlišné od topológie siete mobilných operátorov.

Šveda a kol., 2019, vo svojej štúdiu odhadovali populačnú veľkosť obcí v zázemí Bratislavy s využitím lokalizačných údajov mobilnej siete. Proces suburbanizácie, ktorý sa dnes už týka každej obce v zázemí Bratislavy, nie je možné spoľahlivo zachytiť s využitím tradičných zdrojov údajov. Zámerom štúdie bolo otestovať zmyslupnosť mobilnej lokalizácie ako doplnkového zdroja údajov pre priestorové a populačné analýzy. Išlo o pilotnú štúdiu, keďže v slovenskom prostredí je daná problematika ešte málo preskúmaná. Boli použité dáta troch najväčších slovenských mobilných operátorov zachytávajúce 2,7 milióna užívateľov mobilnej siete. Za účelom identifikovania populačnej veľkosti obce a neprihlásených rezidentov bol vytvorený metodický postup. Na začiatku bol extrahovaný počet užívateľov mobilných telefónov na každej základňovej stanici, ktorej polygón vyžarovania obsluhoval časť sledovaného územia. Počet užívateľov bol sledovaný počas dňa rovnako ako aj počas noci. Ďalej bol počet užívateľov prerozdelený do štvorcovej siete. Následne bol použitý filter využívajúci atribút oficiálnej adresy registrácie SIM karty, vďaka ktorému bol získaný odhad počtu

neprihlásených rezidentov. Pri interpretácii počtu užívateľov mobilných zariadení sa, prirodzene, objavili aj určité limity. Počet SIM kariet nemožno napríklad spoľahlivo stotožniť s počtom osôb, užívateľ SIM karty nemusí byť totožný s držiteľom SIM karty, databáza zahŕňa len užívateľov so SIM kartou registrovanou na fyzickú osobu a presnosť lokalizácie závisí od architektúry mobilnej infraštruktúry, typu antén a reliéfu. Aproximácia neprihlásených rezidentov vychádzala z počtu SIM kariet, ktorých adresa registrácie sa nachádzala v inom okrese. Bolo identifikovaných až 96 000 takýchto užívateľov, pričom ich najväčší počet, až 5230 bol identifikovaný v obci Chorvátsky Grob.

### 3.3.2 Práce zahraničných autorov

Hou a kol., 2019, analyzoval cestovné správanie dospelých starších než 55 rokov v Singapure. Štúdia využívala dáta z HITS (Household Interview Travel Survey) zo Singapuru z roku 2012. Autori sa sústredili na generovanie cesty (trip generation), výber spôsobu prepravy a výber cieľovej destinácie. Porovnávali cestovné správanie starších ľudí a celej populácie a ich výsledky ukazujú, že charakteristiky mobility týchto dvoch skupín sa výrazne líšia. Príkladom toho môže byť, že starší ľudia častejšie absolvujú cesty s iným než pracovným účelom. Boli identifikované dopravné znevýhodnené štvrte, v ktorých sú títo ľudia vysoko závislí na súkromných vozidlách. Zistenia z výskumu môžu byť v budúcnosti využité pri plánovaní využitia územia a dopravy v Singapure s cieľom uspokojiť cestovné požiadavky starnúcej populácie.

Mi-Kyeong a kol., 2018, využívali pri analýze priestorových vzorov dáta z dopravných čipových kariet. Štúdia mala za cieľ identifikáciu vzťahu medzi priestorovými vzormi odvodenými z dát z čipových kariet a mestskými charakteristikami. Hlavné cestovné vzory v nej boli klasifikované do piatich zhlukov identifikovaných pomocou *K-Spectral Centroid clustering method*. Zistilo sa, že časový vzor mestskej mobility reflektuje každodenné aktivity v mestskej oblasti a priestorový vzor piatich zhlukov úzko súvisel so štruktúrou a funkciou mesta. Štúdia potvrdila, že priestorové vzory na úrovni mesta môžu byť použité na pochopenie dynamiky mestskej populácie a priestorovej štruktúry mesta.

Sharmeen a Houston, 2019 prevádzali priestorovú charakteristiku a analýzu priestorových vzorov aktivít v meste Dháka v Bangladéši. Prieskum trval 2 týždne a bolo doňho zapojených 50 domácností. Boli použité 2 metódy, a to konkrétne *shortest path network* a *road network buffer*. Severná časť mesta bola porovnávaná s južnou, pričom boli medzi nimi zistené špecifické rozdiely, napríklad vlastníctvo auta, príjem, prejdene vzdialenosti či dĺžky ciest. Zber dát prebiehal čisto dotazníkovou formou, nakoľko väčšina obyvateľov Dháky nevlastní automobil a zabezpečenie GPS prijímača pre každého respondenta by bolo finančne náročné. Zber prebiehal čase od jesene 2017 do jari 2018. Na priestorovú analýzu získaných dát boli použité nástroje *Kernel Density* a minimálny ohraničujúci polygón – polygón obsahujúci všetky lokality zahrnuté do priestorového vzoru respondenta. Boli tiež použité sieťovo založené metriky, a to *Road Network Buffer*, *Standard Travel Time Polygon* a *Relative Travel Time Polygon*. Okrem priestorovej analýzy boli tiež použité rozličné metódy štatistickej analýzy. Boli prevedené t-testy nad indikátormi ako cestovná vzdialenosť, segmenty cesty, priestor aktivity a dĺžka trvania aktivity. Nad vybranými typmi využitia územia bol vypočítaný index entropie. Za účelom modelovania individuálnej dostupnosti bola v štúdiu použitá deskriptívna štatistika.

Bongiorno a kol., 2019, prispeli k lepšiemu pochopeniu charakteristik nemotorizovanej mestskej mobility s ohľadom na vzdialenosť, časť dňa, trvanie, priestorové rozmiestnenie a počasie. V štúdiu bola prevedená detailná kvantitatívna analýza dát z Bostonskej aglomerácie a zaoberá sa pešou a bikesharingovou mobilitou. Skúmané územie bolo prekryté 100\*100 mriežkou, pričom každá bunka mala šírku 300 m. Dáta o chôdzi boli získané z mobilnej aplikácie a obsahovali celkove 260 000 ciest od 6000 anonymných užívateľov. Bikesharingové dáta boli získané zo stránky Bluebikes, najväčšieho poskytovateľa zdieľaných bicyklov v Bostone, čo sa dá považovať za limitáciu štúdie, keďže veľké množstvo ľudí používa svoje vlastné bicykle. Skúmané boli tri časti dňa, a to ranná špička, čas obeda a poobedná špička. Bola prevedená komparatívna analýza, v ktorej boli jednotlivé cesty rozdelené podľa prejdenej vzdialenosti. V tejto analýze bola skúmaná napríklad reciprocita, teda opačný smer poobedných trás oproti ranným trasám alebo citlivosť na poveternostné podmienky – tu sa prejavila silná korelácia medzi počtom cyklistických výletov za hodinu a teplotou vzduchu.

Musakwa a Selala, 2018, mapovali cyklistické vzory a trendy v Johannesburgu pomocou Strava Metro dát. Strava Metro zbiera dáta užívateľov aplikácie Strava, pričom následne ich anonymizuje, agreguje a konvertuje do GIS formátu. Mapovanie cyklistických vzorov a trendov z dát zo Stravy môže pomôcť pri správe miest a organizácii dopravy. Mapy a dáta získané v rámci štúdie poskytujú holistický súbor údajov o cyklistických vzoroch v Johannesburgu. Cyklistické výlety sú rozdelené na rekreačné, ktoré tvoria 80% a dochádzkové, ktoré tvoria 20% všetkých výletov. Najväčší počet cyklistických výletov bol zaznamenaný v lete, najmenší v zime. Bol rozpoznávaný časový vzor cyklistických výletov, konkrétne sa zistilo, že ich najväčší počet prebiehal v čase od 4:00 do 9:00 a potom od 15:00 do 17:00, pričom v oboch prípadoch sa jednalo o rekreačné aj dochádzkové cesty. V práci boli vytvorené aj zaujímavé vizualizácie cyklistických výletov v jednotlivých mestských častiach, ako aj vizualizácie vzťahu medzi príjmom domácností a počtom cyklistických výletov. Bolo zistené, že bicykel používajú bohatí a ľudia zo strednej vrstvy a oveľa menej ho používajú ľudia s malým alebo žiadnym príjmom. Nevýhodou štúdie je, že nie každý používa Stravu a tým pádom nie sú spracované všetky dáta o používaní bicyklov. Stanovisko autora diplomovej práce je, že práve z toho dôvodu zo štúdie vyplynulo, že len malý počet ľudí s nízkym príjmom používa bicykel – pravdepodobnejšie je, že bicykel používajú, ale nemajú mobilný telefón, na ktorom by si mohli aplikáciu Strava nainštalovať.

### **3.4 Analýza obmedzenia mobility v dôsledku pandémie COVID-19**

Pandémia COVID-19 zvýšila u veľkého množstva ľudí povedomie o priestorových dátach a o rozličných spôsoboch sledovania pohybu osôb. Vďaka tomu vzniklo aj množstvo nových štúdií, ktorých cieľom bolo zistiť, do akej veľkej miery protipandemické opatrenia zamerané na obmedzenie pohybu osôb skutočne znížili ľudskú mobilitu ako aj samotné šírenie nákazy.

Zmenám v mobilite súvisiacim s pandémiou COVID-19 sa počas prvej vlny pandémie na jar 2020 vo svojej prípadovej štúdiu venovali Pászto a kol., 2021. Analyzovali svoje dáta zo služby Google Location z dvoch časových úsekov, konkrétne z obdobia od 1.2. do 10.2., teda pred vypuknutím pandémie a z obdobia od 11.3. do 18.4., teda z času, keď na území Českej republiky platili prísne protipandemické opatrenia. V štúdiu bolo na základe ich dát identifikované ich bydlisko, miesto zamestnania, obchody a miesta

trávenia voľného času, napr. plavecký štadión. Za účelom porovnania dát z dvoch spomínaných časových období boli použité rôzne spôsoby vizualizácie, a to vizualizácia neupravených bodov z Google Location, vizualizácia miest najčastejšieho výskytu užívateľov s počtom bodových záznamov výskytu vzdialených 300, resp. 200 m od nich, agregáciu bodových záznamov výskytu do hexagonálnej siete, vizualizácie výsledkov nástrojov *Calculate Density*, *Find Hot Spots*, a *Find Point Clusters* a mapy intenzity výskytu užívateľov vytvorené na stránke Location History Visualiser. Autori si uvedomujú, že dáta Google Location obsahujú veľké množstvo osobných informácií, ale na druhej strane vyzdvihujú potenciál, aký majú v oblasti monitorovania pohybu osôb v čase pandémie.

Chow a kol., 2021, skúmali vplyv cestovných obmedzení na časopriestorový vzor ľudskej mobility a na počet potvrdených prípadov COVID-19. Štúdia bola prevedená v provincii Hubei v Číne. Cieľom bolo nájsť akýkoľvek významný rozdiel v mobilite ľudí, extrahovať časopriestorové vzory potvrdených prípadov COVID-19 a preskúmať časopriestorový vzťah medzi ľudskou mobilitou a potvrdenými prípadmi COVID-19. V analýze geografických vzťahov medzi ľudskou mobilitou a šírením pandémie v 364 čínskych mestách bola použitá origin-destination matica obsahujúca približne 3 milióny párov bodov. Bola zistená asociácia medzi potvrdenými prípadmi v počiatočných a koncových bodoch. Dáta boli získané od Baidu, spoločnosti poskytujúcej služby založené na polohe užívateľov, ktorá zbiera užívateľské dáta. Geografický vzor mobility pred a po zavedení lockdownu bol počítaný pomocou origin-destination matice, boli tiež využité štatistické testy, konkrétne dve plne faktorové analýzy rozptylu (ANOVA). Výsledky odhalili významné rozdiely v ľudskej mobilite spôsobené lockdownom. Na účely časopriestorovej zhlukovej analýzy bol použitý SaTScan, softvér, ktorý dokáže odhaliť a analyzovať časopriestorové vzory s využitím Kulldorfovej Spatial Scan štatistiky. Bol tiež skúmaný vzťah medzi migračnými vzormi a prípadnými infekčnými zhlukmi. Pri modelovaní sa brala do úvahy aj inkubačná doba ochorenia COVID-19. Vychádzajúc z toho, že ochorenie má inkubačnú dobu 5-14 dní, boli dáta analyzované s 5- alebo 14-dňovým predstihom. Zistilo sa, že modely počítajúce s inkubačnou dobou 5 dní dosahovali lepšie výsledky než tie, ktoré počítali s inkubačnou dobou 14 dní.

Toger a kol., 2021, skúmali, či a pokiaľ áno, tak v akom rozsahu, vedie pandémie COVID-19 k prehodnoteniu funkcie miest ako magnetov ľudskej aktivity. V čase pandémie bolo vo väčšine krajín možné pozorovať nové vzory ľudskej mobility – vytratila sa typická ranná a večerná dopravná špička, zvýšila sa popularita chôdze a cyklistiky a dramaticky pokleslo využívanie hromadnej dopravy. Štúdia využívala dáta zo Švédska poskytnuté mobilnými operátormi z obdobia pred vypuknutím pandémie na jar 2020 a obdobia v priebehu jari počas pandémie. Bola využitá MIND databáza používania mobilných telefónov. Pracovalo sa s dátami z regiónu Štokholm-Uppsala, keďže v tejto oblasti sú vysielacie rozmiestnené nahusto, žije tu 2,5 milióna ľudí a počas normálnych pracovných dní sú presuny medzi mestami v oblasti značné. Okrem mobilných dát boli v práci použité aj dáta zo socioekonomickej databázy PLACE, aby sa zistilo, do akej miery môžu byť zmeny v geografii času asociované so sociodemografickými charakteristikami populácie. Na účely analýzy priestorového správania bol v práci použitý časovo-geografický prístup. Používalo sa modelovanie zdola, pričom sa začínalo od obmedzení limitujúcich rozhodovanie jednotlivcov. Autori pandémie vnímali ako prirodzený experiment ľudskej mobility. Vo vizualizáciách pohybu použitých v práci bol čas braný ako tretí rozmer, bola napríklad vytvorená vizualizácia s použitím metódy časopriestorovej kocky v ArcGIS Pro. Bola taktiež prevedená štatistická analýza. Dáta boli transformované pomocou metódy k-najbližších susedov, aby bolo možné lepšie



pochopiť odlišnosti v časovo-geografickom správaní v rôznych častiach Štokholmskej oblasti. Za účelom zistenia, v akom rozsahu sú časovo-geografické zmeny prepojené so socio-demografickými premennými, bola použitá regresná analýza. Závislou premennou v analýze boli agregované hodnoty reprezentujúce rozdiel v podiele mobilných užívateľov vykonávajúcich nejakú časopriestorovú aktivitu. Nezávislými premennými boli vzdelanie, príjem, výskyt národnostných menšín, vzdialenosť od miesta výkonu práce a nezamestnanosť. Štúdia vo výsledku ukázala, že pandémia má veľký vplyv na geometriu ľudského pohybu v priebehu dňa. Boli tiež pozorované rozdiely medzi rôznymi geografickými časťami sledovanej oblasti (najviac sa vzory pohybu zmenili v prímestských oblastiach) a taktiež súvislosť so socio-demografickými charakteristikami (vzdelanie a príjem pozitívne ovplyvňujú schopnosť meniť vzory pohybu).

## 4 TESTOVANIE VYBRANÝCH METÓD ANALÝZY DÁT GOOGLE LOCATION

Pre účely analýzy dát služby Google Location autor odskúšal široké spektrum metód. Pri tvorbe bakalárskej práce sa zameral len na štatistické analýzy dát v programoch MS Excel a RStudio, ktoré mu pomohli lepšie porozumieť štruktúre dátového záznamu a vybrať záznamy vhodné na ďalšie spracovanie. Spomedzi metód analýzy a vizualizácie dát bola v práci testovaná tvorba máp intenzity javu vytvorených buď s použitím nástroja *Kernel Density* v programe ArcGIS alebo bez možnosti nastavenia parametrov prostredím ArcGIS Online, kde bola vyskúšaná aj tvorba jednoduchej časovej animácie z agregovaných dát. V programe V-Analytics boli z dát Google Location vytvárané líniové trajektórie.

V diplomovej práci autor na svoj výskum z bakalárskej práce nadviazal a sústredil sa na testovanie rôznych ďalších nástrojov analýzy dát z Google Location. Počas práce s rôznymi nástrojmi v geografických a negeografických softvéroch autor zisťoval, aké sú ich výhody a nevýhody a v tejto kapitole sa ich snaží zhodnotiť. Pre lepší prehľad o výhodách a nevýhodách jednotlivých metód a nástrojov bola vytvorená aj tabuľka (Príloha 1).

### 4.1 Analýzy v ArcGIS Pro

V nasledujúcej podkapitole sú popísané rôzne metódy analýzy dát využívajúce nástroje v programe ArcGIS Pro 2.6, ktoré boli testované za účelom analýzy dát Google Location. Podkapitola sa snaží odôvodniť, prečo boli niektoré metódy určené ako vhodné na spracovanie dát v rámci prípadových štúdií, zatiaľ čo výsledky iných metód boli vizualizované len v ukázkových A3 mapách. Výber metód vhodných na použitie v prípadových štúdiách bol konzultovaný s ľuďmi, ktorí svoje dáta pre účely práce poskytnú.

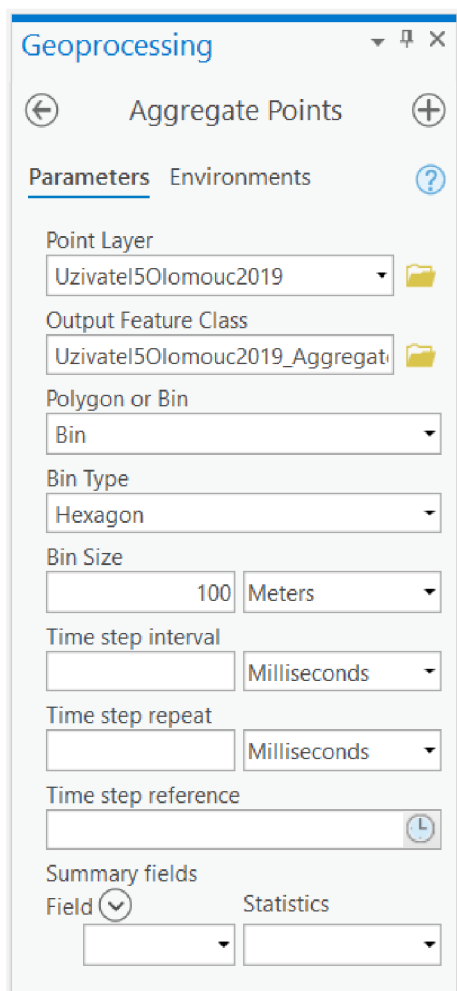
#### 4.1.1 Nástroj Aggregate Points

Nástroj v programe ArcGIS Pro, ktorý je súčasťou *GeoAnalytics* toolboxu, je schopný agregovať bodové dáta buď do polygónovej vrstvy alebo do tzv. binov, ktoré môžu mať tvar štvorcov alebo šesťuholníkov, tzv. hexagónov. V prípade tejto práce boli odskúšané dva spôsoby agregácie, a to do hexagonálnej siete a na polygónovú vrstvu mestských častí Olomouca. V prípade agregácie do hexagonálnej siete bola zvolená dĺžka hexagónu 100 m (Obr. 4.1).

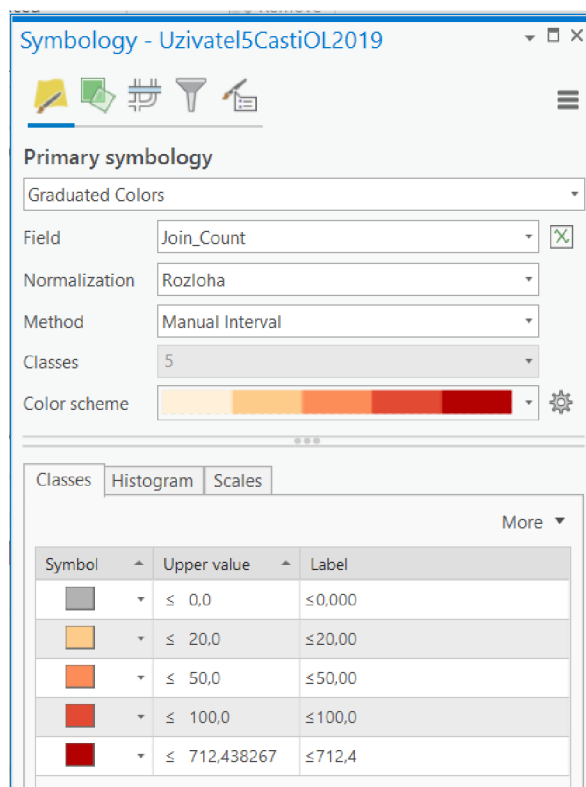
Nástroj je v podstate alternatívou k nástroju *Spatial Join* s tým rozdielom, že v prípade použitia nástroja *Spatial Join* je potrebné najprv sieť vytvoriť pomocou nástroja *Generate Tesselation*. Rozdielom použitia nástroja na vrstvu mestských častí od použitia nástroja *Spatial Join* spočíva v tom, že výsledok z nástroja *Spatial Join* zachováva všetky polygóny vo vrstve, zatiaľ čo výsledok z nástroja *Aggregate Points* zachováva len tie, v ktorých sa nachádzajú nejaké body. Mestské časti, v ktorých sa nenachádzali bodové záznamy bolo však vhodnejšie znázorniť šedou farbou a nie priehľadne a z toho dôvodu bol napokon pre účely vizualizácie výskytu v mestských častiach namiesto nástroja *Aggregate Points* použitý nástroj *Spatial Join*.

Nevýhodou agregácie na mestské časti je, že časti Olomouca majú rôznu rozlohu a preto môžu byť jej výsledky skresľujúce. Skreslenie bolo odstránené vydelením počtu bodov v mestskej časti rozlohou mestskej časti (Obr. 4.2), čím sa získa hustota bodov v mestskej časti na km<sup>2</sup>. Nevýhodou agregácie do hexagonálnej siete je, že vo výsledku nástroja sa zobrazia všetky hexagóny, v ktorých sa daná osoba niekedy vyskytla, čo môže vo výslednej mape pôsobiť rušivým dojmom (Obr. 4.3). Z tohto dôvodu boli z pôvodného výsledku odfiltrované tie hexagóny, v ktorých sa nachádzalo menej než 10 záznamov výskytu užívateľov. Výsledky agregácie do hexagonálnej siete môžu okrem identifikácie najnavštevovanejších miest niekedy pomôcť aj pri identifikácii najčastejších trás. Výsledky agregácie záznamov výskytu na administratívne jednotky môžu byť použité pre štatistické účely.

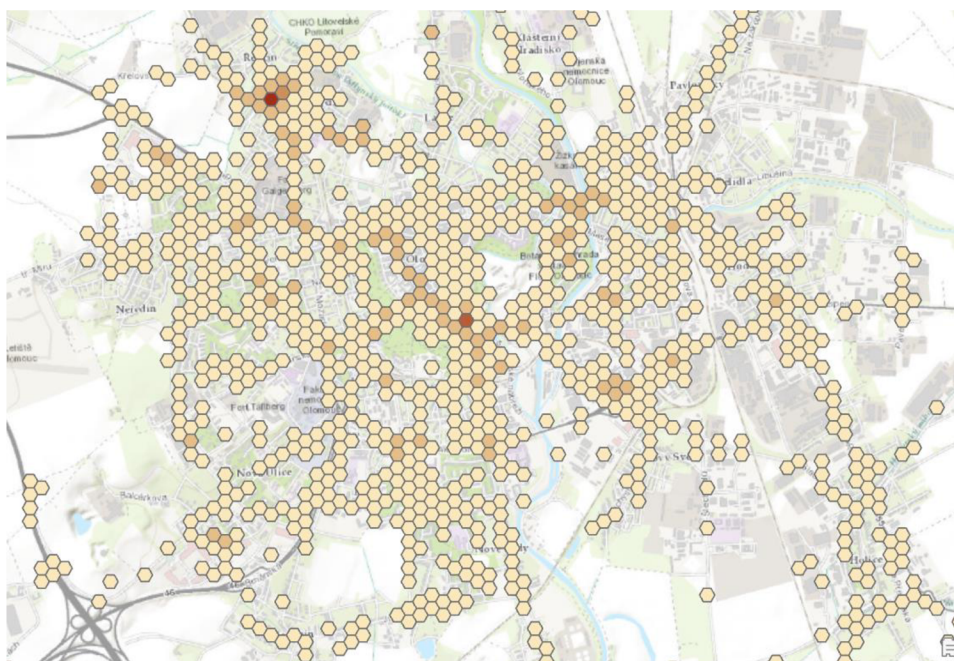
Výsledky agregácie do hexagonálnej siete rovnako ako výsledky agregácie na mestské časti Olomouca mali dostatočnú výpovednú hodnotu na to, aby mohli byť použité v prípadovej štúdií. Okrem dvojíc máp porovnávajúcich mobilitu študentov v dvoch časových obdobiach boli tak ako z výsledkov iných metód vytvorené aj A3 mapy zobrazujúce výsledky analýz dát šiestich užívateľov pomocou týchto metód (Príloha 26 a 27).



Obr. 4.1 – nastavenie nástroja Aggregate Points pri agregácii do hexagonálnej siete



Obr. 4.2 – Normalizácia počtu bodov v mestskej časti rozlohou mestskej časti



Obr. 4.3 – Výsledok agregácie do hexagonálnej siete pred odstránením hexagónov s malým počtom bodov

#### 4.1.2 Výskyt v okolí vybraných bodov záujmu

Inšpiráciou k použitiu tejto kombinácie nástrojov bola prípadová štúdia Pászto a kol., 2021. Pozorovaním bolo zistené, aké inštitúcie sa nachádzajú v blízkosti významných zhlukov bodov. V prípade, že sa jednalo o trvalé či prechodné bydlisko užívateľa, bola táto informácia samotným užívateľom potvrdená. Určovanie polohy

bodov záujmu znázorňuje Obr. 4.4. Na rozdiel od prípadovej štúdie, v ktorej boli klasifikované 4 typy bodov záujmu, a to bydlisko, práca, obchod a voľný čas, boli klasifikované ešte ďalšie 2 typy bodov záujmu a to škola, keďže účastníci výskumu boli študentami a doprava, keďže u viacerých účastníkov sa dali pozorovať významné zhluky bodov v okolí olomouckého hlavného nádražia. Na rozdiel od prípadovej štúdie Pászto a kol., 2021, v ktorej bola obalová zóna bodov záujmu stanovená na 300 m bol v tejto práci stanovený priemer obalových zón na 100 m, a to najmä z dôvodu malej vzájomnej vzdialenosti niektorých bodov záujmu. Poloha bodov záujmu bola u užívateľov stanovená hľadaním významných zhlukov bodov a zisťovaním, aké objekty sa na ich miestach nachádzajú. Nezriedka sa stalo, že v niektorých lokalitách sa u užívateľov v jednom sledovanom období nachádzalo veľké množstvo bodov, zatiaľ čo v druhom období sa tam nenachádzal žiaden, prípadne len malé množstvo bodov, čo je možné vidieť aj vo vytvorených porovnávacích mapách porovnávajúcich 2 sledované obdobia (Príloha 6, 11, 16 a 21), ktoré boli použité v prípadovej štúdií

Metóda je vhodná hlavne na porovnanie výskytu užívateľov vo vybraných lokalitách v rôznych sledovaných obdobiach. Na samotnú identifikáciu miest najčastejšieho výskytu je vhodnejšie použiť iné metódy. Nevýhodou metódy je, že body záujmu boli určené len na základe hľadania miest s vysokou koncentráciou bodov bez použitia akéhokoľvek výpočtu. Pri vizualizácii výsledkov metódy sa tiež stráca informácia o celkovej mobilite užívateľa.

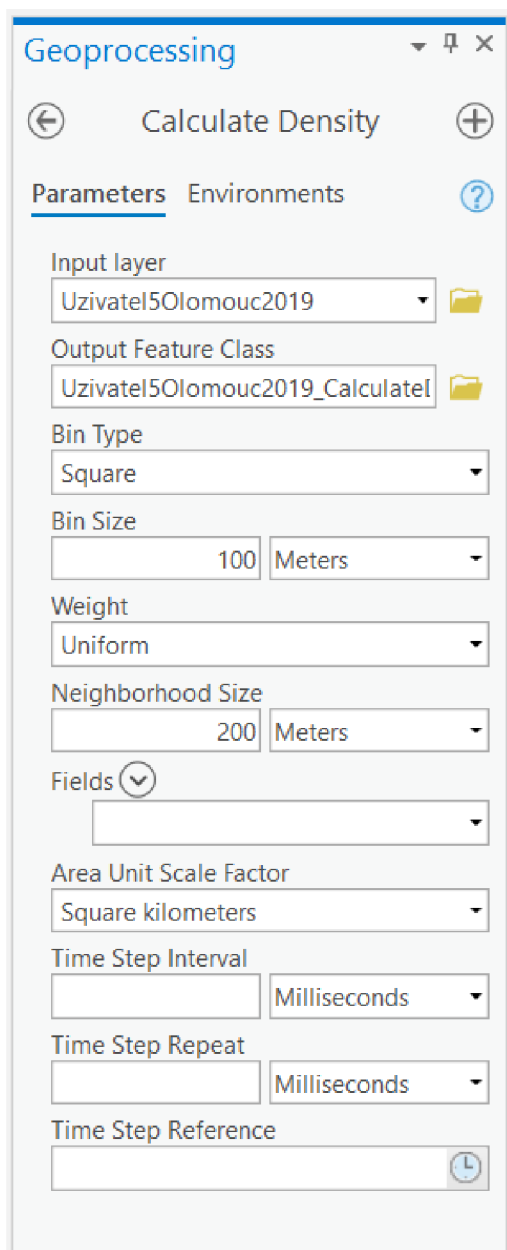


Obr. 4.4 – Určovanie polohy bodov záujmu v lokalitách s významnými zhlukmi bodov

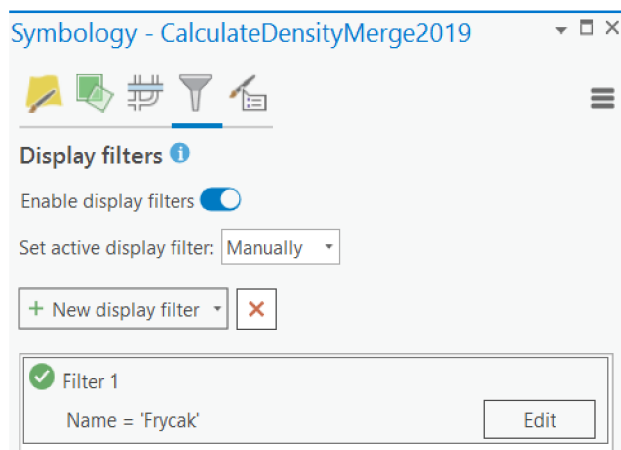
### 4.1.3 Nástroj Calculate Density

Nástroj by sa dal považovať za vektorovú alternatívu nástroja *Kernel Density*. Je súčasťou *GeoAnalytics* toolboxu v *ArcGIS Pro*. Podľa *ArcGIS Pro* geoprocessing tool reference (ďalej dokumentácia nástrojov v *ArcGIS Pro*) počíta nástroj plochu na

jednotku bodových prvkov, ktoré spadajú do susedstva v okolí každej bunky. Nastavenie parametrov nástroja použité v práci znázorňuje Obr. 4.5. Výsledok nástroja siete môže pomôcť pri identifikácii najčastejšie navštevovaných lokalít, ale nepôsobí esteticky príliš príťažlivo a má nižšiu výpovednú hodnotu oproti výsledku agregácie do hexagonálnej siete ako aj oproti výsledku nástroja *Kernel Density*. Z výsledkov nástroja bola teda vytvorená len vizualizácia porovnávajúca dáta šiestich užívateľov a výsledky neboli použité v prípadovej štúdii. Nastavovanie jednotnej symbológie výsledkov nástroja pre všetkých 6 máp bolo problematické, preto bol na výsledky nástroja pre jednotlivých užívateľov použitý nástroj *Merge*, ktorý ich spojil do jedného súboru, ktorý bol skopírovaný do všetkých mapových okien. Po skopírovaní bolo v jednotlivých oknách v nastavení *Symbology* v záložke *Display filters* nastavené zobrazenie výsledkov konkrétnych užívateľov (Obr. 4.6 )



Obr. 4.5 – Nastavenie parametrov nástroja Calculate Density

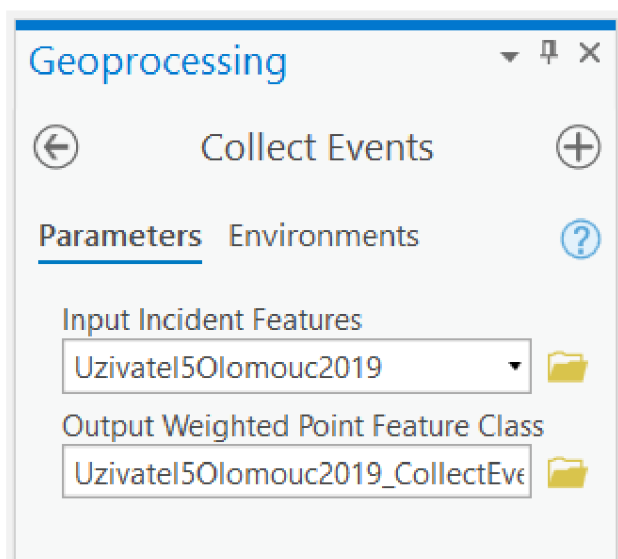


Obr. 4.6 – Nastavenie filtra symbológie

#### 4.1.4 Nástroj Collect Events

Nástroj, ktorý je súčasťou *Spatial Statistics* toolboxu, podľa dokumentácie nástrojov v ArcGIS Pro konvertuje dáta týkajúce sa udalostí, napríklad trestných činov alebo výskytov ochorení na vážené bodové dáta. Pri spustení nástroja nie je možné nastaviť žiadne ďalšie parametre (Obr. 4.7). Ako istá nevýhoda tohto nástroja sa ukázalo byť to, že vážené body boli vytvorené len z bodov s úplne identickými súradnicami a často sa napríklad stávalo, že v miestach častého výskytu užívateľov vzniklo namiesto jedného veľkého váženého bodu niekoľko vážených bodov rôznych veľkostí (Obr. 4.8). Toto bolo vyriešené čiastočnou modifikáciou výsledku tohto nástroja. Najprv boli odfiltrované tie body, v ktorých bola hodnota Atribútu COUNT nižšia než 5. Následne bola okolo novovzniknutých bodov vytvorená 50 metrová obalová zóna pomocou nástroja *Buffer*. Keďže sa niektoré obalové zóny prekrývali, boli následne spojené s použitím nástroja *Dissolve Boundaries*. Do výsledku bola následne dodaná informácia o počte bodov nachádzajúcich sa v polygóne pomocou nástroja *Spatial Join*. Z výsledku, ktorý obsahoval informácie o počte bodov (výskytov) na území ohraničenom polygónmi, bol následne získaný centroid pomocou nástroja *Feature To Polygon*. Vzniknutým bodom sa nastavila symbológia, aby boli zobrazené ako Proportional symbols podľa atribútu Count. Problematické bolo nastavenie jednotnej symbológie vo viacerých mapových oknách, ktoré bolo podobne ako v prípade nástroja Calculate Density vyriešené zlúčením výsledkov do jedného súboru, prekopírovaním do jednotlivých okien a aplikovaním filtra na zobrazované prvky v konkrétnom okne. Po takejto úprave vznikla vizualizácia, ktorá už mala väčšiu výpovednú hodnotu, hoci u niektorých užívateľov sa nezobrazili niektoré významné miesta výskytu, ktoré boli dobre viditeľné vo výsledkoch iných nástrojov. Napriek tomu však bolo rozhodnuté, že výsledky majú dostatočnú výpovednú hodnotu na to, aby mohli byť použité v prípadovej štúdií.

Výsledok nástroja po vyššie popísanej úprave a nastavení symbológie veľmi dobre vypovedá o intenzite výskytu užívateľa v najčastejšie navštevovaných lokalitách, stráca sa však informácia o najčastejších trasách medzi lokalitami.



Obr. 4.7 – Chýbajúca možnosť nastavenia parametrov v nástroji Collect Events



Obr. 4.8 – Ukážka výsledku nástroja Collect Events pred úpravou

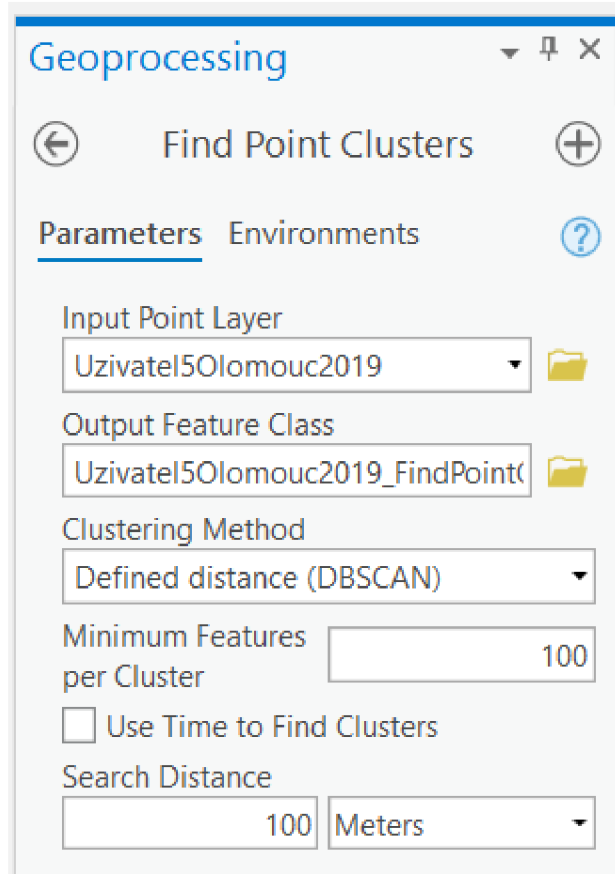
#### 4.1.5 Nástroj Find Point Clusters

Nástroj *Find Point Clusters*, ktorý je súčasťou *GeoAnalytics* toolboxu, podľa dokumentácie nástrojov v ArcGIS Pro hľadá zhluky bodových prvkov v okolí hluku na základe ich priestorového alebo časopriestorového rozloženia. Pri nastavovaní parametrov je možné vybrať si spomedzi dvoch metód zhlukovania. Metóda definovanej vzdialenosti (*DSCAN*) používa *DBSCAN* algoritmus a hľadá zhluky bodov, ktoré sú vedľa seba v tesnej blízkosti. Metóda umožňuje nájsť zhluky buď v dvojrozmernom priestore alebo v priestore a čase. Samo-nastavovacia (self-adjusting) *HDBSCAN* metóda používa *HDBSCAN* algoritmus a hľadá zhluky bodov s použitím rôznych vzdialeností. Umožňuje vytvorenie zhlukov s rôznou hustotou bodov na základe pravdepodobnosti alebo stabilnosti zhľuku. Všetky dáta, ktoré boli pre účely práce poskytnuté, boli analyzované pomocou metódy *DBSCAN* (Obr. 4.9) V zhlukoch, ktoré boli s jej pomocou vytvorené, bolo väčšinou problematické nájsť nejaký význam, a to aj v spolupráci s respondentmi, ktorí svoje dáta pre účely práce poskytli. Z tohto dôvodu sa rozhodlo, že výsledky



nástroja nebudú použité v prípadovej štúdií porovnávajúcej mobilitu pred vypuknutím pandémie a v jej priebehu a budú vizualizované v sumarizujúcej A3 mape (Príloha 31).

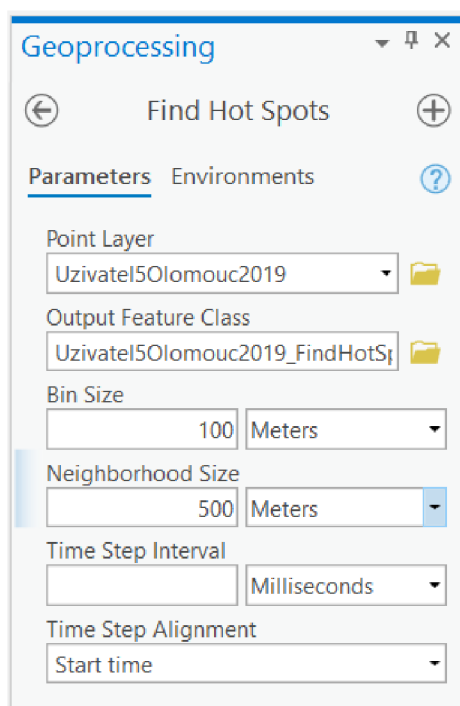
Za výhodu metódy sa dá považovať, že výsledky nástroja pôsobia esteticky príťažlivo, nepodarilo sa však úplne porozumieť princípu, na akom nástroj funguje. Je možné, že z iných typov bodových dát dokáže nástroj vytvoriť zmysluplnejšie výsledky.



Obr. 4.9 – Nastavenie parametrov nástroja Find Point Clusters

#### 4.1.6 Nástroj Find Hot Spots

Nástroj *Find HotSpots*, ktorý je súčasťou toolboxu *GeoAnalytics*, podľa dokumentácie nástrojov v ArcGIS Pro identifikuje štatisticky významné Hot Spoty (zhluky veľkého množstva prvkov) a Cold Spoty (zhluky malého množstva prvkov) s použitím Getis-Ord  $G_i^*$  štatistiky. V prípade dát z Google Location boli vytvorené len Hot Spoty a žiadne Cold Spoty, čo bolo spôsobené charakterom dát z Google Location. Nastavenie parametrov pri spustení nástroja, ktoré bolo v práci použité, znázorňuje Obrázok 4.10. Ukázalo sa, že nástroj nie je úplne najvhodnejší na analýzu daného typu dát a jeho výsledky mohli v niektorých prípadoch pôsobiť trochu zavádzajúcim dojmom a preto neboli použité v prípadovej štúdií, ale boli vizualizované len v sumarizujúcej A3 mape (Príloha 32).

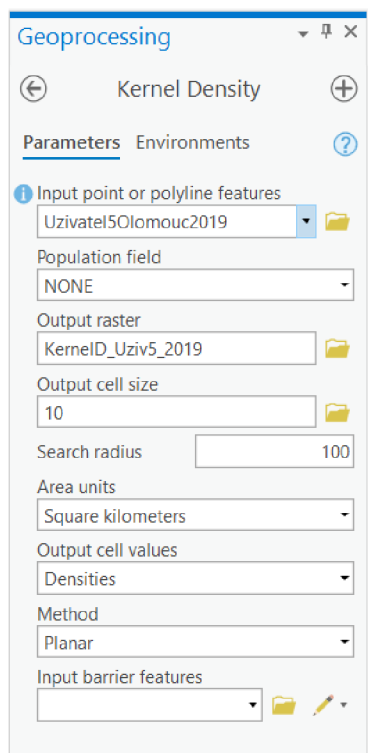


Obr. 4. 10 – Nastavenie parametrov nástroja Find Hot Spots

#### 4.1.7 Nástroj Kernel Density

Nástroj *Kernel Density*, ktorý je súčasťou *Spatial Analyst* toolboxu, podľa dokumentácie ArcGIS Pro vytvára z bodových alebo líniových prvkov oblasti s použitím jadrovej funkcie rastrový povrch. Výslednú podobu vytvoreného rastru ovplyvňuje nastavenie parametrov *Search Radius* a *Output Cell Size*. Dalo by sa povedať, že nástroj slúži na vytváranie máp intenzity výskytu užívateľov, ale na rozdiel od vytvárania takýchto máp prostredníctvom *Location History Visualiser* alebo ArcGIS Online má užívateľ väčšie možnosti pri nastavovaní vstupných parametrov a symbológie. Nastavenie parametrov nástroja, ktoré bolo v práci použité, ilustruje Obrázok 4.11. Vo výsledku, ktorý je po spustení nástroja v ArcGIS Pro vygenerovaný, sa zobrazovalo len malé množstvo najčastejšie navštevovaných lokalít. Po vhodnom prestavení symbológie však bolo možné získať vizualizácie s pomerne veľkou výpovednou hodnotou a preto bolo možné použiť výsledky analýzy v prípadovej štúdií.

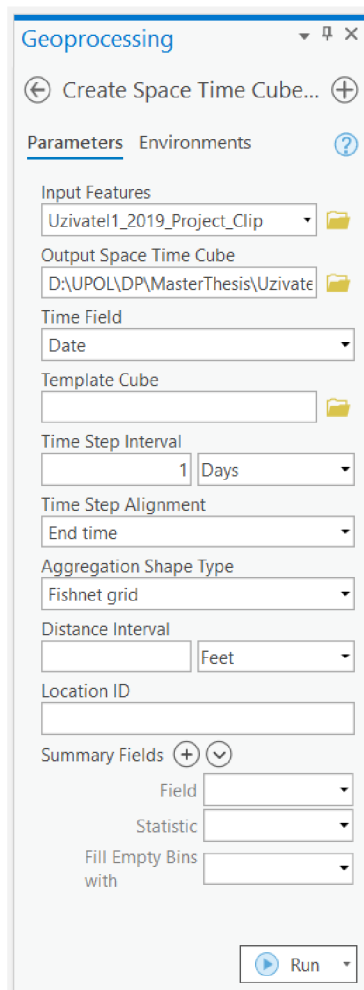
Nástroj je vhodné použiť pri tvorbe máp intenzity výskytu užívateľov, z ktorých je možné vyčítať informácie jednak o najčastejšie navštevovaných lokalitách a súčasne aj o najčastejších trasách, čo z neho robí ideálny nástroj na hľadanie priestorových vzorov (prihliadnuc na definíciu priestorového vzoru vytvorenú na základe naštudovanej literatúry v kapitole 3.1). Nevýhodou môže byť veľký objem výsledku nástroja a to hlavne pri jeho aplikácii na dáta z rozľahlejších oblastí.



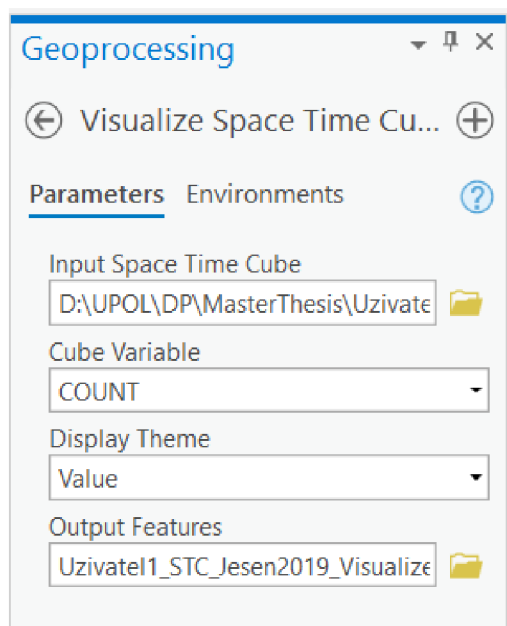
Obr. 4.11 – Nastavenie parametrov nástroja Kernel Density použité v práci

#### 4.1.8 Space Time Cube

Časopriestorovú kocku v netCDF formáte je v programe ArcGIS Pro možné vytvoriť pomocou nástroja *Create Space Time Cube By Aggregating Points* (Obr. 4.12) a jej následná vizualizácia je možná pomocou nástroja *Visualize Space Time Cube in 3D* (Obr. 4.13). Oba nástroje sú súčasťou toolboxu *Space Time Pattern Mining*. Podľa dokumentácie ArcGIS Pro nástroj *Create Space Time Cube By Aggregating Points* sumarizuje sadu bodov do netCDF dátovej štruktúry prostredníctvom ich agregácie do časopriestorových zásobníkov. V rámci každého zásobníka sú spočítané body a agregované špecifické atribúty. Výstupom nástroja je jedinečným spôsobom generovaná trojrozmerná reprezentácia. Náhľad na časopriestorovú kocku vytvorenú z dát Užívateľa 1 z Olomouca z obdobia od 22. 10. do 22. 11. 2019 poskytuje Obr. 4.13. Problematickou sa javí byť kartografická vizualizácia výstupov tohto nástroja. Nedávalo zmysel vizualizovať výsledky vo forme 2D mapy. Pri konzultácii bolo autorovi odporučené vyskúšať export 3D scény do ArcGIS Online, avšak z technických príčin tento export nebolo možné zrealizovať. Výsledky analýzy dát šiestich užívateľov z územia v Olomouci z obdobia od 22. 10. do 22. 11. 2019 sú k dispozícii k nahliadnutiu na SD karte v zložke *Projekty* v súbore *SpaceTimeCube.aprx*.



Obr. 4.12 – Nastavenie parametrov nástroja Create Space Time Cube by Aggregating Points



Obr. 4.13 – Nastavenie parametrov nástroja Visualize Space Time Cube in 3D

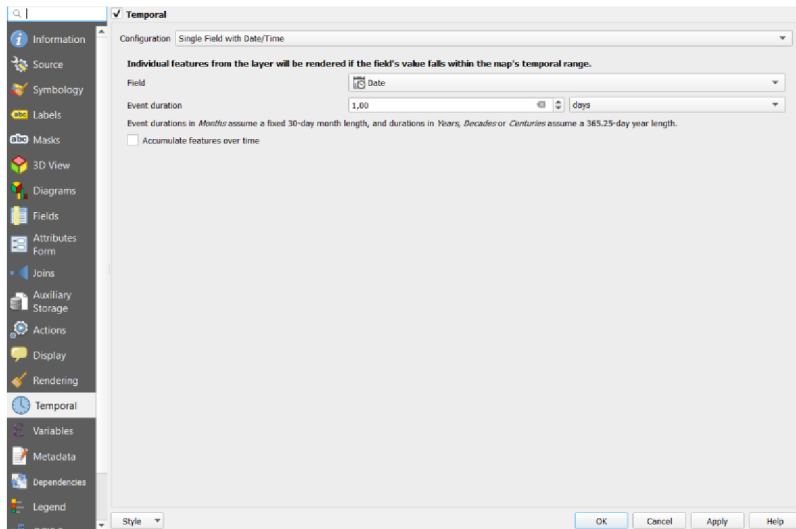


Obr. 4.14 – Náhľad na časopriestorovú kocku vytvorenú z dát Užívateľa 1

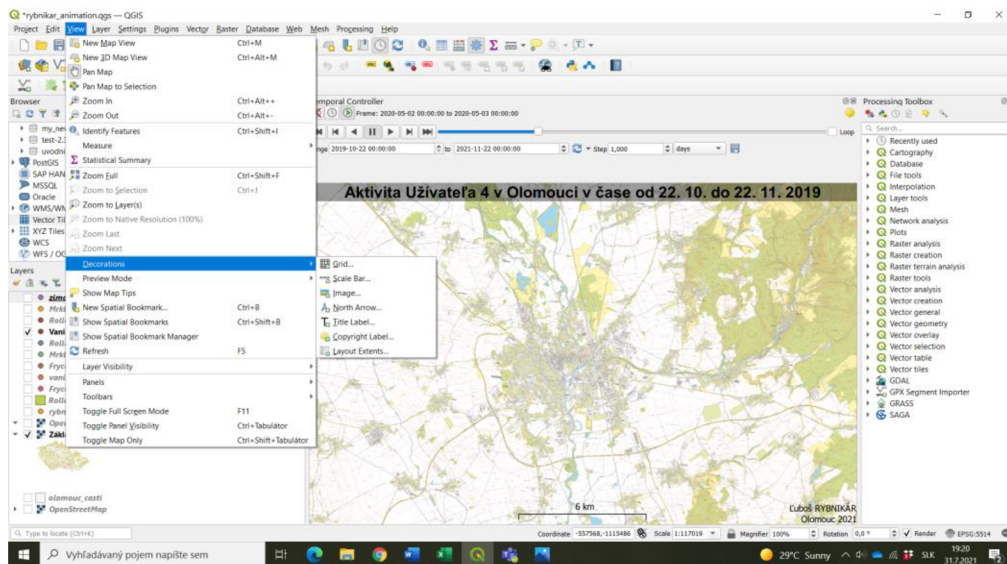
## 4.2 Časopriestorová animácia v QGIS

V programe QGIS Desktop 3.18.1 boli vytvorené časopriestorové vizualizácie pohybu študentov katedry pomocou pluginu *Temporal Controller*. S pluginom sa autor oboznámil počas letnej školy ISSonVis na Katedre geoinformatiky. Plugin je dostupný od verzie QGIS 3.14. Na to, aby bola možná animácia bodových dát, je potrebné najprv vo vlastnostiach dátového súboru v záložke *Temporal* nastaviť, ktoré pole obsahuje časový údaj (v našom prípade je to pole *Date*) a aká je dĺžka trvania časového údaja, čo je v našom prípade jeden deň (Obr. 4.15). Po tomto kroku je potrebné nastaviť časový rozsah a dĺžku kroku a ďalej je už možné animáciu spustiť. Do animácie boli pridané aj kompozičné prvky mapy, konkrétne názov, mierka a tiráž, a to pomocou nastavenia *View->Decorations* (Obr. 4.16). Animáciu je možné taktiež uložiť, nevytvorí sa však video, ale séria obrázkov (Obr. 4.17), z ktorých boli vytvorené animácie pomocou nástroja *Animated GIF Maker* na webovej stránke <https://ezgif.com/maker>.


Vytvorené animácie zaujímavým spôsobom vizualizujú pohyb osôb v čase a priestore, preto bolo rozhodnuté použiť ich v prípadovej štúdií. Podnetom pre ďalšie práce môže byť vytvorenie animácií z nielen samotného bodového záznamu z Google Location, ale aj výsledkov analýz nad dátami prevedených.



Obr. 4.15 – Časové nastavenie vo vlastnostiach dátového súboru



Obr. 4.16 – Pridávanie kompozičných prvkov do mapy vo forme dekorácií



Obr. 4.17 – Séria obrázkov vyexportovaná z programu QGIS

### 4.3 Kontingenčné tabuľky v MS Excel

Program MS Excel 2016 bol v práci použitý za účelom vytvorenia kontingenčných tabuliek z dát z Google Location z územia mesta Olomouc. Okrem toho bol program použitý aj pri porovnávaní záznamov histórie polohy s dátami z denníka, ktorí si respondenti po dobu jedného týždňa vyplňali (Prílohy 35–38) pri tvorbe tabuľkového prehľadu existujúcich štúdií (Príloha 34) a prehľadu testovaných metód analýzy dát.

V kontingenčných tabuľkách boli porovnávané dáta užívateľov z dvoch období a to z 22. 10. – 22.11. 2019 a 22.10. – 22.11.2020. Výsledky porovnávania sú podrobnejšie popísané v nasledujúcej kapitole. Cieľom práce bolo skúmať mobilitu v rámci mesta Olomouc, preto sa pracovalo čisto len s dátami pre mesto Olomouc. Pred exportom do formátu XLSX bol v atribútovej tabuľke pridaný atribút *ActivityType*, v ktorom bol určený typ aktivity tým záznamom, v ktorých hodnota istoty daného typu aktivity bola rovná alebo vyššia než 50. Táto hodnota nebola stanovená náhodne, ale jej stanovenie vychádzalo z poznatkov získaných pri tvorbe bakalárskej práce. Neboli určované všetky typy aktivity, ale len EXITING VEHICLE, IN VEHICLE, ON BICYCLE, RUNNING, STILL a WALKING. Ostatné typy aktivity neboli určované a to buď z toho dôvodu, že sa s inými typmi aktivity môžu vyskytovať súčasne (ON FOOT, IN RAIL VEHICLE, IN ROAD VEHICLE, IN TWO WHEELS VEHICLE, IN FOUR WHEELS VEHICLE) alebo nemajú pre účely práce zásadnejší význam (TILTING, UNKNOWN). Po exportovaní boli v programe MS Excel pridaný stĺpec *day*, v ktorom bol pomocou aplikovania funkcie DENTÝDNE určený deň a stĺpec *hour*, v ktorom bola pomocou funkcie ZLEVA určená hodina. Vo všetkých XLS dokumentoch boli vytvorené celkovo 4 kontingenčné tabuľky. Dokumenty sú k dispozícii na SD karte v zložke *KontingencneTabulky*. Tabuľky v liste *TypAktivity* spolu s grafom vyjadrujú početnosť vybraných typov aktivity jednotlivých užívateľov v priebehu vybraných období. Je to trochu iný prístup k rôznym typom aktivity, než bol zvolený v bakalárskej práci, v ktorej boli vytvárané vizualizácie jednotlivých typov aktivity. Tabuľky a grafy v liste *Datum* vyjadrujú počet bodových záznamov na území Olomouca v priebehu jednotlivých dní. Tabuľky a grafy v liste *Hodina* vyjadrujú počet záznamov v priebehu jednotlivých hodín. Tabuľky a grafy v liste *DenVTyzdni* vyjadrujú počet záznamov v priebehu jednotlivých dní v týždni. V období od 22. 10. do 22. 11. 2019 sa počty jednotlivých dní v týždni líšili od obdobia od 22.10. do 22.11.2020 (viď Tab. 4.1). Na elimináciu tohto efektu sa autor rozhodol vydeliť celkové počty bodov zaznamenaných počas jednotlivých dní v týždni počtom konkrétnych dní v danom mesiaci. Takto boli získané priemerné počty bodov za jednotlivé dni v týždni.

Výsledky metódy boli použité v prípadovej štúdií, keďže dobre slúžia najmä pri hľadaní časových vzorov pohybu osôb a ich zmien v rôznych časových obdobiach. Výhodou metódy je, že prostredníctvom nej môžu analyzovať dáta Google Location aj ľudia bez znalostí práce v GIS. V tejto práci boli pomocou metódy analyzované len dát z krátkych časových úsekov, ale analýza dát z dlhších časových období by mohla priniesť ešte zaujímavejšie výsledky.

	22. 10. – 22. 11. 2019	22. 10. – 22. 11. 2020
Pondelok	4	4
Utorok	5	4
Streda	5	4
Štvrtok	5	5
Piatok	5	5
Sobota	4	5
Nedeľa	4	5

Tab. 4.1 – Počet jednotlivých dní týždňa v priebehu dvoch sledovaných období.


## 4.4 Ďalšie spôsoby analýzy a vizualizácie dát

Okrem spôsobov analýzy a vizualizácie dát predstavených v predchádzajúcich podkapitolách sa pôvodne uvažovalo aj nad využitím ďalších nástrojov. Táto podkapitola dané nástroje predstavuje a snaží sa odôvodniť, prečo boli len odskúšané, ale na dôkladnú analýzu všetkých dát neboli použité.

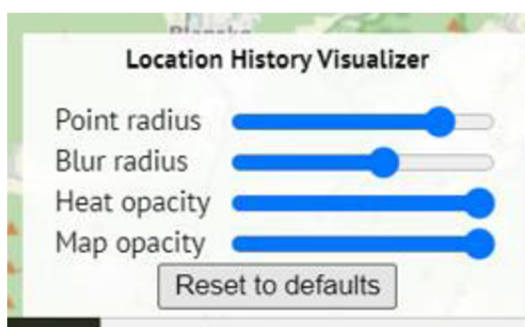
### 4.4.1 Location History Visualiser

Location History Visualiser je podľa dokumentácie z Githubu nástroj na vizualizáciu úplnej a konsolidovanej zhromaždenej Google histórie polohy. Pracuje priamo vo webovom prehliadači, kde po nahratí záznamu z Google Location a zadaní mailovej adresy vytvorí mapu intenzity výskytu užívateľa (Obr.4.18). Pracuje pri tom s balíkmi leaflet.js, leaflet.heat, filestream, oboe.js a browserify. Užívateľ má možnosť ovplyvniť aspoň základné parametre zobrazenej mapy intenzity javu (Obr. 4.19). Tento nástroj pracuje iba s dátami vo formáte JSON. Toto môže byť výhodou pre tých, ktorí nedokážu, prípadne nemajú čas konvertovať záznam do iných formátov. Nevýhodou ale je, že tým pádom nie je možné doňho nahráť napríklad dáta iba z určitého časového intervalu alebo určitej oblasti. Cieľom tejto práce je analýza dát z Olomouca vo vybraných časových obdobiach a takto odfiltrované dáta nie je možné do nástroja nahráť. Z tohto dôvodu tento nástroj nebol použitý.





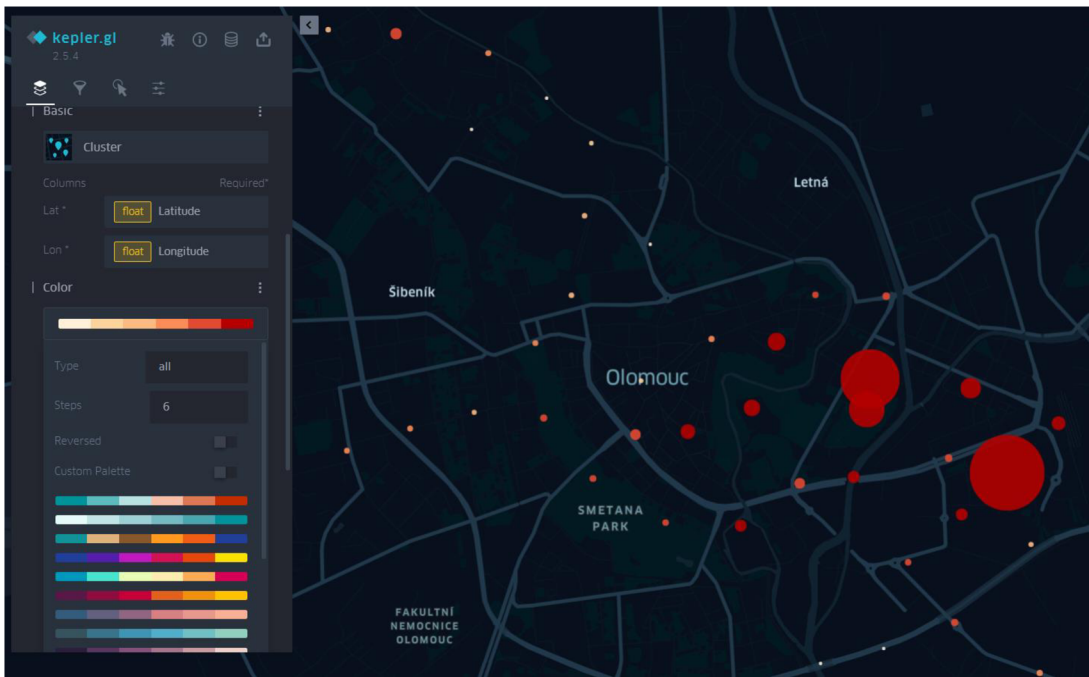
Obr. 4.18 – Ukážka vizualizácie dát Užívateľa 2 priblíženej na územie mesta Olomouc



Obr. 4.19 – Nastavenie parametrov heatmapy vytvorenej pomocou Location History Visualiser

#### 4.4.2 Kepler GL

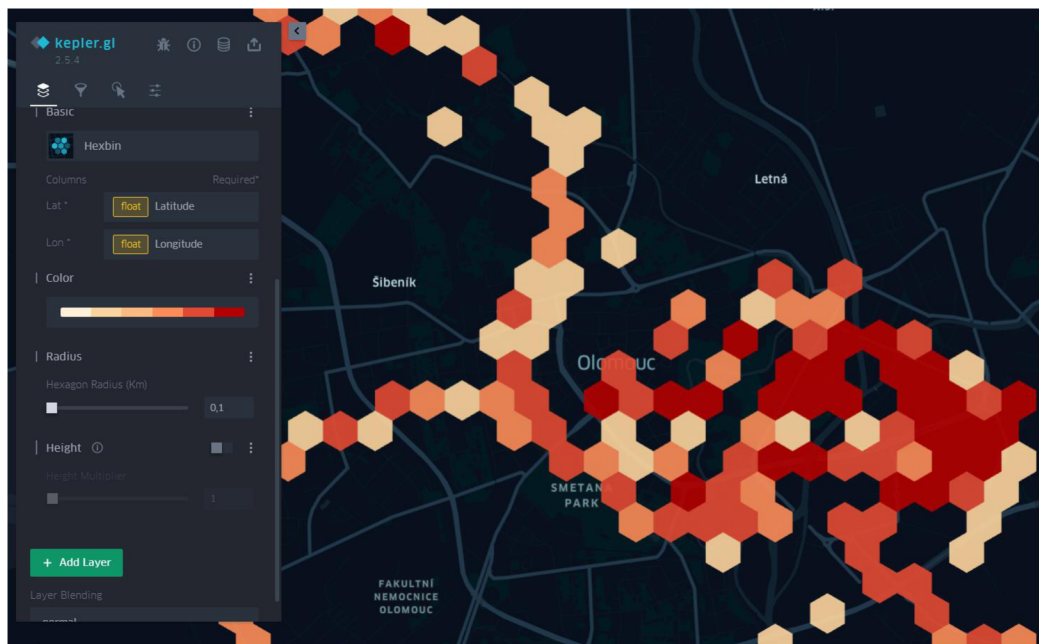
Kepler.gl je podľa užívateľskej príručky internetový nástroj vytvorený pre účely geopriestorovej analýzy dát. Umožňuje vizualizáciu veľkého množstva dát o polohe vo webovom prehliadači. Podporuje formáty CSV, GeoJSON a súbory vo formáte JSON vyexportované z Kepler GL. Pokusy o nahranie kompletnej histórie polohy prekonvertovanej z formátu JSON do formátu GeoJSON zlyhali z dôvodu príliš veľkého objemu dát. Do formátu GeoJSON je však možné aj spätne konvertovať časovo a priestorovo orezaný záznam vo formáte SHP a na rozdiel od Location History Visualiser tu teda nie je nutné nahráť celý záznam z Google Location. Na ukážku bol nahraný záznam Užívateľa 5 z Olomouca z obdobia od 22. 10. do 22. 11. 2019. Dáta je možné zobrazíť napríklad vo forme bodov alebo je možné zvoliť vizualizáciu vo forme zhlukov (Obr. 4.20), čo môže čiastočne pripomínať upravený výsledok nástroja *Collect Events*. Takisto je možný výstup vo forme mapy intenzity javu (Obr. 4.21) či bodov agregovaných do hexagonálnej siete (Obr. 4.22). Získané dátové vizualizácie môžu pôsobiť príťažlivo, ale autor sa rozhodol pri tvorbe práce uprednostniť výsledky analýz v programe ArcGIS Pro, z ktorých sa dajú tvoriť analógové mapové výstupy.



Obr. 4.20 – Ukážka vizualizácie dát Užívateľa 2 vo forme bodových zhlukov približenej na územie mesta Olomouc



Obr. 4.21 – Ukážka vizualizácie dát Užívateľa 2 vo forme mapy intenzity javu približenej na územie mesta Olomouc



Obr. 4.22 – Ukážka agregácie dát Užívateľa 2 do hexagonálnej siete približenej na územie mesta Olomouc

## 4.5 Zhodnotenie výhod a nevýhod použitých metód

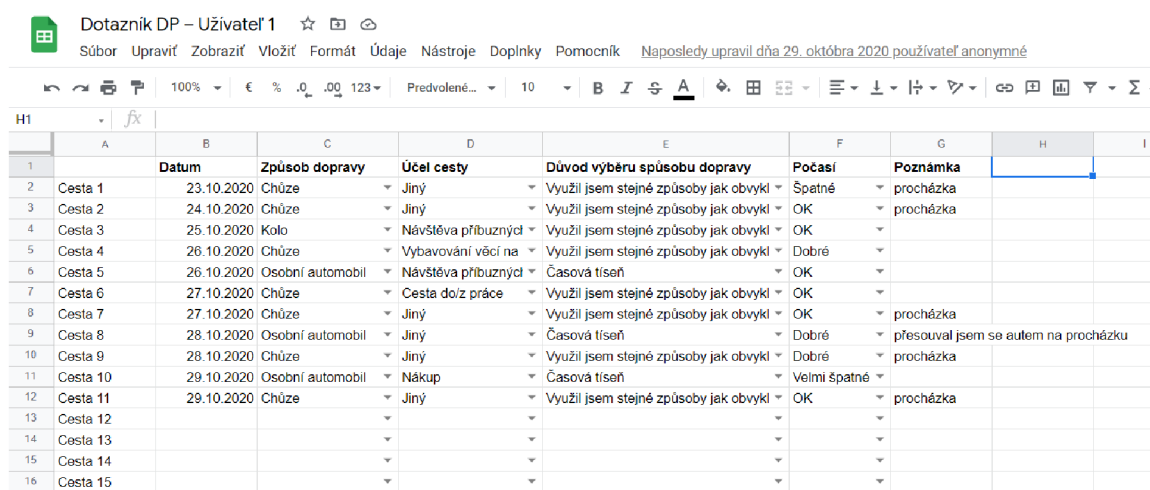
Prírodzene sa môže objaviť otázka, ktorá z vyššie popísaných metód môže byť najvhodnejšou pre účely analýzy dát služby Google Location. Odpoveďou je, že zrejme neexistuje jedna ideálna metóda a výber metód by mal súvisieť s účelom spracovania dát. Dáta o výskyte používateľov Google Location v jednotlivých územných celkoch, v prípade tejto práce v mestských častiach Olomouca, môžu byť vhodné na štatistické účely. Na porovnanie dát o výskyte vo vybraných lokalitách v priebehu rôznych časových období sa ako najvhodnejšia javí vizualizácia výskytu v okolí vybraných bodov záujmu a vizualizácia upraveného výsledku nástroja *Collect Events*. Pre účely identifikácie najčastejších trás sú najvhodnejšie výsledky nástroja *Kernel Density* a agregácie do hexagonálnej siete. Na identifikáciu časových vzorov pohybu a ich zmien v priebehu rôznych časových období sú najvhodnejšie výsledky časových animácií a grafy vytvorené z kontingenčných tabuliek. Kontingenčné tabuľky a grafy je taktiež možné využiť aj na zistenie počtu jednotlivých typov aktivity v zázname.

## 5 ANALÝZA DÁT VYBRANÝCH ŠTUDENTOV

Dáta štyroch študentov, ktorí ich pre účely diplomovej práce poskytli, boli analyzované v prípadovej štúdii s cieľom zistiť, ako pandémia COVID-19 zmenila ich bežné priestorové vzory pohybu. Na začiatku prípadovej štúdie boli dáta študentov porovnané s dotazníkovými dátami s cieľom validácie dátových záznamov z Google Location. Z dôvodu nutnosti anonymizácie dát boli účastníkom výskumu pridelené pseudonymy Užívateľ 1 – 4, pod ktorými vystupujú v texte práce a v jej prílohách.

### 5.1 Porovnanie dát z Google Location s dotazníkovými dátami

Za účelom hodnotenia kvality a presnosti dát bolo rozhodnuté o doplnení dát z Google Location dotazníkovými dátami z krátkeho časového obdobia. Štyria účastníci výskumu, študenti Katedry geoinformatiky, boli požiadaní, aby si jeden týždeň zapisovali svoju aktivitu do denníka v Google Tabuľkách (Obr. 5.1). Účastníci tento čas úplne nedodržali a niektorí vyplňali dotazník kratšie, iní dlhšie než jeden týždeň. Cieľom bolo zistiť, ako veľmi sú podobné, respektíve ako sa líšia zapísané dáta od dát zo záznamu z Google Location. V dotazníku boli aj otázky týkajúce sa účelu cesty, dôvodu výberu spôsobu dopravy a počasia, ktoré napokon pre účely práce nemali žiaden význam a vo verzii s komentárom boli odstránené. Dotazníkové záznamy s komentárom autora práce sú k dispozícii ako Prílohy 35–38 na SD karte v zložke *Dotazniky*, stručnému popisu dotazníkov a zistení z nich sa venuje táto podkapitola.



	A	B	C	D	E	F	G	H	I
1		Datum	Způsob dopravy	Účel cesty	Důvod výběru způsobu dopravy	Počasí	Poznámka		
2	Cesta 1	23.10.2020	Chůze	Jiný	Využil jsem stejné způsoby jak obvykl	Špatné	procházka		
3	Cesta 2	24.10.2020	Chůze	Jiný	Využil jsem stejné způsoby jak obvykl	OK	procházka		
4	Cesta 3	25.10.2020	Kolo	Návštěva příbuzných	Využil jsem stejné způsoby jak obvykl	OK			
5	Cesta 4	26.10.2020	Chůze	Vybavování věci na	Využil jsem stejné způsoby jak obvykl	Dobré			
6	Cesta 5	26.10.2020	Osobní automobil	Návštěva příbuzných	Časová tiseň	OK			
7	Cesta 6	27.10.2020	Chůze	Cesta do/z práce	Využil jsem stejné způsoby jak obvykl	OK			
8	Cesta 7	27.10.2020	Chůze	Jiný	Využil jsem stejné způsoby jak obvykl	OK	procházka		
9	Cesta 8	28.10.2020	Osobní automobil	Jiný	Časová tiseň	Dobré	přesouval jsem se autem na procházku		
10	Cesta 9	28.10.2020	Chůze	Jiný	Využil jsem stejné způsoby jak obvykl	Dobré	procházka		
11	Cesta 10	29.10.2020	Osobní automobil	Nákup	Časová tiseň	Velmi špatné			
12	Cesta 11	29.10.2020	Chůze	Jiný	Využil jsem stejné způsoby jak obvykl	OK	procházka		
13	Cesta 12								
14	Cesta 13								
15	Cesta 14								
16	Cesta 15								

Obr. 5.1 – Ukážka dotazníka v podobe, v akej ho účastníci výskumu vyplňali v Google Tabuľkách

V prípade Užívateľa 1 môžeme pozorovať čiastočnú zhodu dotazníkových dát s dátami zo záznamu z Google Location. Problémom je vo väčšine dní veľmi malé množstvo dátových záznamov, v ktorých by sa dal určiť typ aktivity. Na rozdiel od iných užívateľov sa u neho nevyskytujú iné typy pohybovej aktivity než tie, ktoré uviedol.

Užívateľ 2 vyplňal dotazník len v čase, keď sa vyskytoval v Olomouci, čo boli v jeho prípade len 4 dni. V jeho zázname z Google Location sa veľká zhoda s údajmi z dotazníka nedá nájsť a často sa vyskytujú iné typy aktivity než tie, ktoré uviedol.

V prípade Užívateľa 3 je väčšinou problémom malé množstvo bodov, ktoré by potvrdzovalo, že v daných časoch vykonával daný typ aktivity. Vyskytujú sa aj iné typy

aktivity, než sú opísané vo vyplňovanej tabuľke, to je však pravdepodobne spôsobené tým, že si do dotazníka nezapísal všetky aktivity, ktoré v priebehu dňa vykonával.

Spomedzi štyroch užívateľov sa najpresnejším javí byť záznam Užívateľa 4, v ktorom je pomerne veľká zhoda zápiskov v denníku so záznamom z Google Location a problémom zostáva len to, že si užívateľ do denníka zväčša zapisoval len jazdu dopravnými prostriedkami a zanedbával pri tom iné typy aktivity, ktoré však niekedy spomenul aspoň v poznámkach. Užívateľ si dobrovoľne zapisoval svoju aktivitu dlhší čas, než to bolo stanovené, čo je však dobré, pretože tým poskytol pre účely práce väčšie množstvo dát, s ktorými sa dá pracovať.

Výsledkom validácie dát z Google Location je, že v záznamoch sa väčšinou vyskytuje len malé množstvo bodov odpovedajúcich typom aktivity, ktorú ľudia v danom čase vykonávali. Autor už vo svojej bakalárskej práci zistil, že väčšine bodových záznamov z Google Location sa nedá jednoznačne priradiť žiaden typ aktivity. Je to prekvapivé, keď sa vezme do úvahy, že na Google časovej osi bývajú typy aktivity určené pomerne presne.

## **5.2 Prípadová štúdia – analýza zmien priestorových vzorov pohybu študentov pôsobených pandémiou**

Hlavným cieľom prípadovej štúdie bolo zistiť, ako veľmi pandémia ovplyvnila každodennú mobilitu a priestorové vzory pohybu osôb v Olomouci. Ako už bolo niekoľkokrát spomínané, svoje dáta pre účely práce poskytli len štyria študenti, čo nie je príliš veľké množstvo ľudí a toho dôvodu bol hlavný dôraz kladený na otestovanie rozličných metód priestorovej a časovej analýzy pohybu osôb. Svoje dáta síce dodatočne poskytli ďalší dvaja študenti, tieto dáta však boli značne neúplné z toho dôvodu, že službu Google Location mávali aktívovanú len príležitostne. Autor mal k dispozícii aj dáta troch zamestnancov katedry, ktoré boli použité v prípadovej štúdii *Changing Mobility Lifestyle: A Case Study on the Impact of COVID-19 Using Personal Google Locations Data* (Pászto a kol., 2021) a svoje dáta mu dodatočne poskytol aj ďalší zamestnanec katedry, rozhodol sa však, že vo svojej práci sa primárne sústreďí na analýzu dát študentov. Boli teda porovnávané dáta štyroch študentov z dvoch rovnakých časových úsekov v rokoch 2019 a 2020, konkrétne od 22. 10. do 22. 11. Jedno sledované obdobie bolo teda ešte pred vypuknutím pandémie a druhého v jej priebehu. Hoci aj autor sám je študentom, jeho dáta nemohli byť použité v prípadovej štúdii, pretože v druhom sledovanom období sa v Olomouci vôbec nevyskytoval. Účastníci výskumu boli pôvodne požiadaní o zapnutie zaznamenávania polohy len v čase od 22. 10. do 22. 11. 2020, ale keďže dáta, ktoré poskytli, obsahovali aj záznamy histórie polohy z rovnakého časového obdobia v roku 2019, bolo rozhodnuté porovnať dáta z dvoch časových období.

Za účelom porovnania vybraných dát boli pomocou analytických metód popísaných v kapitole 4 vytvorené mapové vizualizácie porovnávajúce tieto dve časové obdobia. Boli taktiež vytvorené kontingenčné tabuľky a grafy z dát z dvoch sledovaných období, ktorých porovnávaním bolo možné pozorovať zmeny časových vzorov pohybu osôb. Informácie o rozdieloch časových vzorov v dvoch sledovaných obdobiach dopĺňajú aj animácie vytvorené v programe QGIS 3.18. Pri porovnávaní vytvorených mapových a nemapových vizualizácií bolo cieľom hľadať a porovnávať priestorové a časové vzory pohybu študentov v dvoch sledovaných obdobiach a tým naplniť stanovené ciele práce. Predpokladom, ktorý sa mal týmto pozorovaním overiť bol, že v čase pandémie COVID-

19 a z nej vyplývajúcich protipandemických opatrení trávia ľudia väčšie množstvo času doma a menšie množstvo času na pracovisku, v škole, v reštauráciách, baroch a v iných miestach trávenia voľného času a súčasne je znížená aj ich celková mobilita.

### 5.2.1 Dáta Užívateľa 1

Pri porovnávaní vizualizácií výskytu užívateľa v okolí **bodov záujmu** (Príloha 6) je možné pozorovať nielen dôsledky pandémie, ale aj zmeny bydliska užívateľa. Na jeseň v roku 2019 trávil užívateľ najväčšie množstvo času v škole a v Café Jan. Na nákupy chodil do OC Globus. Na mape z roku 2020 môžeme vidieť najčastejší výskyt v mieste nového bydliska na Varšavskom námestí. V dôsledku zmeny miesta trvalého bydliska sa zvýšil výskyt v nákupnom centre Globus a užívateľ začal nakupovať aj v nákupnom centre Šantovka, kde sa rok predtým vôbec nevyskytoval. Z dôvodu zatvorenia vysokých škôl a zavedenia dištančnej výučby sa znížil výskyt užívateľa v okolí katedry geoinformatiky.

Keď sa pozrieme na vizualizácie výskytu užívateľa **v mestských častiach** Olomouca (Príloha 7), nie je vidieť žiadne výraznejšie zmeny a najvýraznejším sa javí byť pokles výskytu v mestskej časti Hodolany. To je pravdepodobne spôsobené tým, že užívateľ v sledovanom období v roku 2020 nevyužíval železničnú dopravu a z toho dôvodu sa nevyskytoval na hlavnom nádraží. V oboch obdobiach trávil užívateľ najviac času v časti Olomouc-město. Menší výskyt na katedre geoinformatiky bol vykompenzovaný častým výskytom v mieste nového bydliska, ktoré sa tiež nachádza v tejto mestskej časti.

Vo vizualizácii dát agregovaných do **hexagonálnej siete** (Príloha 8) môžeme vidieť, že v sledovanom období v roku 2019 trávil užívateľ najviac času na Katedre geoinformatiky a v jej blízkom okolí, a to najmä v menze a v budove Prírodovedeckej fakulty. Na mape je možné vidieť aj náznak trasy z Katedry geoinformatiky na železničnú stanicu. Častý výskyt môžeme pozorovať v už spomínanom Café Jan a v reštaurácii U Kapličky, v ktorej sa konala školská akcia Gisnight. O rok neskôr trávil užívateľ väčšinu času v mieste nového bydliska, odkiaľ často chodil na prechádzky do blízkych Smetanových a Čechových sadov a do OC Šantovka. Naďalej tiež navštevoval Café Jan.

Vo vizualizácii upravených výsledkov z nástroja **Collect Events** (Príloha 9) môžeme vidieť, že v sledovanom období v roku 2019 trávil užívateľ najviac času na Katedre geoinformatiky a výskyt na iných miestach v Olomouci bol oproti tomu zanedbateľný. V rovnakom období v roku 2020 trávil v mieste svojho nového bydliska ešte výrazne viac času než rok predtým na Katedre geoinformatiky.

Keď sa pozrieme na **mapy intenzity výskytu** (Príloha 10) užívateľa v Olomouci z dvoch sledovaných období, môžeme vidieť nielen najčastejšie navštívené miesta v Olomouci, ale aj najčastejšie trasy medzi nimi. Vo vizualizácii dát zo sledovaného obdobia v roku 2019 je výrazná najmä trasa z Katedry geoinformatiky na železničnú stanicu, ktorú bolo možné pozorovať aj v hexagonálnej sieti. O rok neskôr je podobne ako vo vizualizácii dát agregovaných do hexagonálnej siete možné pozorovať časté prechádzky v Smetanových a Čechových sadoch. Po konfrontácii s mapou intenzity svojho výskytu užívateľ konštatoval, že je v nej veľmi dobre vidieť, kedy mal zapnutú aplikáciu Strava, ktorá využíva GPS signál a vďaka používaniu ktorej bolo aj zaznamenávanie polohy v Google Location častejšie a tým pádom sú dané trasy v mape intenzity výskytu viditeľné. Na iných trasách, na ktorých užívateľ nemal aplikáciu zapnutú, bolo zaznamenávanie polohy menej presné a tieto trasy sa v heatmape nezobrazujú. Čo sa týka najčastejšie navštívených miest, v sledovanom období v roku

pred pandémiou je to hlavne Katedra geoinformatiky, ale častý výskyt sa dá pozorovať aj v Café Jan, v reštaurácii u Kapličky a v okolí Androvho štadióna. V sledovanom období v roku 2020 výrazne dominuje nové miesto trvalého bydliska užívateľa.

Pri porovnávaní **animovaných vizualizácií** pohybu užívateľa v priebehu jedného mesiaca v rokoch 2019 a 2020 (Prílohy 39 a 40) sa dajú viac než dopady pandémie pozorovať dopady zmeny miesta trvalého bydliska. Kým v sledovanom období v roku 2019 sa v niektoré dni v Olomouci vôbec nevyskytoval, v roku 2020 tu trávil každý deň.

Porovnávaním grafov vytvorených z **kontingenčných tabuliek** z dát z Olomouca z dvoch sledovaných období (Príloha 2) sa dá dospieť k zaujímavým poznatkom. V oboch obdobiach výrazne prevažuje typ aktivity STILL, ktorý je nasledovaný typom aktivity WALKING, z čoho sa dá usúdiť, že užívateľ v Olomouci často zotrval na jednom mieste (pričom z predchádzajúcich vizualizácií bolo zistené, že v období v roku 2019 bola týmto miestom hlavne Katedra geoinformatiky, zatiaľ čo v období v roku 2020 ním bolo najmä nové miesto trvalého bydliska) a po meste sa najčastejšie presúval pešo. K najzaujímavejšiemu zisteniu sa dá dospieť pri porovnávaní grafov výskytu užívateľa v Olomouci v priebehu jednotlivých dní v týždni, v ktorom sa odzrkadľuje zmena trvalého bydliska užívateľa. Kým v období v roku 2020 je počet bodov zaznamenaných na území Olomouca pomerne rovnomerný, s jedným výraznejším maximom vo štvrtok, v období v roku 2019 sa užívateľ len minimálne vyskytoval v Olomouci v piatok, sobotu a nedeľu, teda v dňoch, keď nemal žiadne hodiny na Katedre geoinformatiky. V grafe zobrazujúcom výskyt v Olomouci v priebehu jednotlivých hodín môžeme vidieť, že najnižší počet bodov bol u užívateľa zaznamenaný v oboch prípadoch v nočných hodinách. V období v roku 2019 bolo najviac bodov zaznamenaných medzi dvanástou a šestnástou hodinou, v roku 2020 bolo o osemnástej zaznamenaných výrazne viac bodov než v iných hodinách. Pri pozorovaní grafov zobrazujúcich výskyt v priebehu jednotlivých dní v mesiaci sa dá dospieť k podobnému záveru ako pri porovnávaní grafov zobrazujúcich počet bodov v priebehu jednotlivých dní v týždni. Môžeme vidieť, že v roku 2019 sa užívateľ vyskytoval v Olomouci hlavne v čase, keď mal výuku na Katedre geoinformatiky, o rok neskôr bol počet zaznamenaných bodov jeho výskytu rovnomernejší s menšími občasnými výkyvmi.

Pri **celkovom zhodnotení dát** Užívateľa 1 môžeme skonštatovať, že väčší dopad než pandémie COVID-19 mala na zmenu jeho priestorových vzorov pohybu v rámci mesta Olomouc zmena miesta jeho trvalého bydliska. Najvýraznejším dopadom pandémie na jeho mobilitu bolo zníženie výskytu na Katedre geoinformatiky a v jej okolí. Za dôsledok jednak pandémie a súčasne aj zmeny miesta trvalého bydliska sa dá považovať absencia trasy z Katedry geoinformatiky na hlavné nádražie v dátach zo sledovaného obdobia z roku 2020. Je zaujímavé, že viaceré spôsoby vizualizácie užívateľových dát naznačovali, že sa v oboch sledovaných obdobiach často vyskytoval v Café Jan, čo však samotný užívateľ vyvrátil s tým, že v danom podniku nikdy nebol a často okolo neho len prechádzal. Rovnako často len prechádzal okolo Androvho štadióna a do OC Globus nechodil takmer vôbec.

### 5.2.2 Dáta Užívateľa 2

Na vizualizáciu dát Užívateľa 2 sú mapové výrezy vo vizualizáciách bodov záujmu, hexagonálnej siete a v mapách intenzity výskytu užívateľa v Olomouci posunuté inak než u iných užívateľov a to z toho dôvodu, že užívateľ mal v sledovanom období v roku 2020 brigádu v mestskej časti Holice, ktorá by sa na mapách pri použití rovnakého výrezu ako u iných užívateľov nezobrazovala.

Pri porovnávaní vizualizácií výskytu v okolí **bodov záujmu** (Príloha 11) môžeme pozorovať pokles výskytu užívateľa v okolí Katedry geoinformatiky, ale naopak nárast výskytu na hlavnom vlakovom nádraží a vo firme v mestskej časti Holic, v ktorej, ako to sám uviedol pri konzultácii, príležitostne chodil na brigádu. V sledovanom období v roku 2020 sa vôbec nevyskytoval v mieste trávenia voľného času, teda v reštaurácii U Kapličky, ale naopak viac času trávil v obchodnom dome Kaufland.

Vo vizualizácii agregácie bodových záznamov užívateľa na **mestské časti** Olomouca (Príloha 12) môžeme vidieť, že v oboch sledovaných obdobiach trávil najviac času v časti Olomouc-město. V sledovanom období v roku 2020 sa vôbec nevyskytoval v Lazcoch, Hejčine, Řepčine a Chválkoviciach, kde bol jeho výskyt rok predtým relatívne častý. O niečo častejší bol v sledovanom období v roku 2020 jeho výskyt v Holic, čo sa dá odôvodniť už spomínanou brigádou v tejto mestskej časti.

Vo vizualizáciách bodových záznamov užívateľa agregovaných do **hexagonálnej siete** (Príloha 13) je vidieť, že v sledovanom období v roku 2019 trávil užívateľ najviac času na Katedre geoinformatiky, Koleji Generála Svobody a v ich blízkom okolí, v reštaurácii U Kapličky na Flash Wall a na križovatke Husovej a Komenského ulice. V sledovanom období v roku 2020 trávil najviac času na koleji Generála Svobody a na hlavnom nádraží trávil viac času oproti sledovanému obdobiu v predošlom roku.

Z vizualizácií získaných úpravou výsledkov z nástroja **Collect Events** (Príloha 14) vyplýva, že sledovanom období v roku 2019 trávil užívateľ na Katedre geoinformatiky a Koleji Generála Svobody výrazne viac času, než v iných lokalitách, v ktorých sa vyskytoval. O rok neskôr trávil najviac času na Koleji Generála Svobody, ale bol tam výrazne menej, než v rovnakom období v predchádzajúcom roku.

Z dvojice **máp intenzity výskytu** užívateľa v Olomouci (Príloha 15) vyplýva, že v sledovanom období v roku 2019 trávil užívateľ najviac času na Koleji Generála Svobody a na Katedre geoinformatiky. O rok neskôr boli dominantnými miestami jeho výskytu Kolej Generála Svobody a hlavné nádražie. V mapách sa tiež črtajú náznaky niektorých trás, vo vizualizácii zo sledovaného obdobia v roku 2020 je napríklad možné vidieť trasu z miesta prechodného bydliska na miesto práce, ale tieto trasy nie sú také výrazné, ako v mapách intenzity výskytu iných užívateľov.

Pri porovnávaní **animácií** vizualizujúcich bodové záznamy užívateľa z dvoch sledovaných období (Prílohy 41 a 42) môžeme vidieť, že ani v období v roku 2019 sa užívateľ nevyskytoval v Olomouci denne, no jeho výskyt v Olomouci v druhom sledovanom období bol skutočne zriedkavý.

Keď porovnáme grafy vytvorené pomocou **kontingenčných tabuliek** vytvorených zo záznamov histórie polohy Užívateľa 2 (Príloha 3), môžeme si všimnúť podstatné rozdiely vo výskyte v Olomouci spôsobené pandemickou situáciou. Pri porovnávaní grafov vyjadrujúcej frekvenciu výskytov jednotlivých typov aktivity si môžeme všimnúť, že v sledovanom období v roku 2019 výrazne prevažoval typ aktivity STILL. Podobne to bolo aj o rok neskôr, tu však v pomere k nemu častejšie objavovali aj typy aktivity IN VEHICLE, RUNNING A WALKING. V grafe výskytu užívateľa v Olomouci v priebehu jednotlivých dní v sledovaných obdobiach je možné vidieť, že kým v sledovanom období v roku 2019 strávil užívateľ v Olomouci 19 dní, v rovnakom období v roku 2020 tu bol len 7 dní, čo je takmer trojnásobne menej. Z grafov zobrazujúcich výskyt užívateľa v Olomouci v priebehu jednotlivých dní v týždni môžeme zistiť, že zatiaľ čo v sledovanom období v roku 2019 sa užívateľ vyskytoval v Olomouci 5 dní od pondelka do piatku a víkendy tam nikdy netrávil, o rok neskôr sa okrem víkendov nikdy v Olomouci nevyskytoval ani vo štvrtok. V sledovanom období v roku 2019 boli najmenšie množstvá bodových záznamov užívateľa v Olomouci zaznamenané v nočných hodinách, najvyššie



množstvá bodov bývali zaznamenávané v čase od 6. do 12. hodiny o niečo menej ich bývalo o 13. a 14. hodine, o 15. hodine začal ich počet opätovne stúpať, až kým nedosiahol o 18. hodine svoje maximum, v nasledujúcich hodinách potom počet záznamov striedavo klesal a stúpal. V rovnakom období v roku 2020 bol práve naopak o 18. hodine zaznamenaný najmenší počet bodov. V sledovanom období v roku 2020 bol u užívateľa zaznamenaný najvyšší počet bodov o 6. hodine a v popoludňajších hodinách. Počet bodov zaznamenaných v Olomouci vo večerných hodinách v roku 2020 bol podstatne nižší než v predchádzajúcom roku a nízky bol aj jeho výskyt v Olomouci v nočných hodinách, z čoho sa dá usúdiť, že užívateľ v Olomouci väčšinou neprespával a prichádzal tam len na jeden deň.

Užívateľ 2 nemá v Olomouci svoje trvalé bydlisko, má tu len prechodné bydlisko na Koleji Generála Svobody, čo spôsobilo, že ani v roku 2019 sa tu nevyskytoval každodenne. V rovnakom období v roku 2020 sa tu však v dôsledku zavedenia dištančnej výučby vyskytoval v podstatne menšej miere. Predpoklad o vplyve pandémie na priestorový vzor užívateľa na začiatku kapitoly sa na území Olomouca potvrdil čiastočne. Užívateľ síce trávil podstatne menej času v škole, ale na druhej strane sa príležitostne vyskytoval na pracovisku, na ktorom sa rok predtým nevyskytoval vôbec.

### 5.2.3 Dáta Užívateľa 3

Pri pohľade na vizualizáciu výskytu užívateľa v okolí vybraných **bodov záujmu** v dvoch sledovaných obdobiach (Príloha 16) môžeme vidieť, že na rozdiel od predchádzajúcich dvoch užívateľov mal Užívateľ 3 miesto trvalého pobytu v Olomouci pred pandemiou aj v jej priebehu. Ako miesto bydliska boli identifikované až dva body, jeden u jeho rodičov a druhý u jeho priateľky (táto informácia nebola získaná odhadom, ale poskytol ju sám pri konzultácii) a výskyt v okolí týchto bodov bol v oboch sledovaných obdobiach vyšší než výskyt v okolí Katedry geoinformatiky. Môžeme tiež vidieť, že zatiaľ čo v sledovanom období v roku 2019 trávil väčšie množstvo času u rodičov, o rok neskôr ho viac trávil u priateľky, čo sa však nedá považovať za dôsledok protipandemických opatrení. V sledovanom období v roku 2020 sa užívateľ vôbec nevyskytoval na Katedre geoinformatiky, s čím by sa dala dať do súvislosti aj absencia výskytu v OC Šantovka, ktoré sa nachádza v blízkosti katedry. Užívateľ miesto toho preferoval nákup v OC Globus, ktoré sa nachádza bližšie dvom bodom, ktoré boli definované ako jeho bydlisko. Výskyt v okolí OC Haná sa výraznejšie nezmenil. Keď sa pozrieme na lokality klasifikované ako miesta trávenia voľného času, môžeme vidieť, že v reštaurácii U Kapličky sa v druhom sledovanom období nevyskytoval vôbec a podstatne sa znížil aj jeho výskyt na Hornom námestí. Menej častý výskyt v okolí hlavného nádražia sa dá vysvetliť tým, že užívateľ v čase pandémie menej využíval železničnú dopravu.

Pri pohľade na vizualizáciu výskytu Užívateľa 3 v **mestských častiach** Olomouca (Príloha 17) sa dá vidieť, že kým v sledovanom období v roku 2019 bol dominantný v troch mestských častiach Neředín, Nová Ulice a Olomouc-město, o rok neskôr trávil najviac času v Neředíne. Pokles výskytu v časti Nová Ulice je spôsobený zrejme tým, že v danom období trávil viac času u priateľky než u rodičov. Za dôsledok protipandemických opatrení sa dá považovať značný pokles jeho výskytu v časti Olomouc-město. Na druhej strane môžeme pozorovať, že sa zvýšil jeho výskyt v častiach Svätý Kopeček, Lošov a Radíkov, čo sa dá odôvodniť tým, že podobne ako veľké množstvo ďalších ľudí začal v čase pandémie častejšie chodiť na prechádzky do prírody.

Pri pohľade na vizualizácie dát užívateľa agregovaných do **hexagonálnej siete** (Príloha 18) môžeme vidieť, že v sledovanom období pred pandémiou mal dve dominantné miesta výskytu, a to u rodičov a u priateľky, zatiaľ čo o rok neskôr nad ostatnými dominoval výskyt u priateľky. Jediná trasa, ktorá sa dá vyčítať pri pohľade na obe vizualizácie, je trasa medzi dvoma miestami označenými ako bydlisko, teda trasa z bydliska u rodičov do bydliska u priateľky. V sledovanom období v roku 2020 je výskyt v hexagónoch mimo tejto trasy len minimálny. V roku 2019 sa ich výraznejšie zhluky dajú pozorovať okrem okolia Katedry geoinformatiky aj v centrálnej časti mesta.

Pri pohľade na vizualizáciu upravených výsledkov nástroja **Collect Events** (Príloha 19) môžeme vidieť, že v sledovanom období v roku 2019 trávil užívateľ najviac času u rodičov a častý bol aj jeho výskyt u priateľky a na Katedre geoinformatiky, pričom jeho výskyt v iných lokalitách bol oproti týmto miestam zanedbateľný. V rovnakom období v roku 2020 trávil najviac času u priateľky a o niečo menej u rodičov, iné miesta jeho výskytu sa vo vizualizácii vytvorenej touto metódou vôbec nezobrazujú.

Z dvojice **máp intenzity výskytu** užívateľa v Olomouci (Príloha 20) vyplýva, že v sledovanom období v roku 2019 trávil najviac času u rodičov, u priateľky a na Katedre geoinformatiky, ale okrem toho sa veľmi často vyskytoval aj na rôznych miestach v centrálnej časti mesta Olomouc. Z mapy sa dajú dobre vyčítať aj jeho najčastejšie trasy, pričom najvýraznejšie sú trasy od rodičov k priateľke, od rodičov do centrálnej časti mesta a od rodičov do jedálne Gastroflash (samotný Užívateľ 3 potvrdil, že do tejto jedálne chodieval a súčasne mal v jej blízkosti aj kanceláriu), o niečo menej výrazná je aj trasa z centra na katedru. V rovnakom období v roku 2020 boli podľa mapy intenzity výskytu miesta najčastejšieho výskytu u priateľky a u rodičov, častý výskyt sa dá pozorovať aj na križovatke Hněvotínskej a Albertovej ulice pri Fakultnej nemocnici. Najčastejšia trasa užívateľa bola podľa mapy intenzity výskytu od rodičov ku priateľke, dá sa tiež identifikovať aj o niečo menej častá trasa od rodičov na Horní náměstí. To, ako dobre bolo u Užívateľa 3 z výsledkov nástroja *Kernel Density* možné identifikovať najčastejšie navštívené miesta a súčasne najčastejšie trasy, potvrdzuje tvrdenie z kapitoly 4, že nástroj je ideálny na hľadanie priestorových vzorov pohybu osôb.

Pri pozorovaní a porovnávaní **animovaných máp** záznamov užívateľa (Prílohy 42 a 43) z dvoch sledovaných období je vidieť, že v čase pandémie sa Užívateľ 3 presúval na menšie vzdialenosti než v období pred pandémiou a podobne ako to vyplynulo aj z iných vizualizácií, jeho najčastejšie cesty v čase pandémie boli od priateľky k rodičom.

Z grafov vytvorených z **kontingenčných tabuliek** vytvorených z dát Užívateľa 3 (Príloha 4), sa taktiež dajú pozorovať zmeny medzi dvomi sledovanými obdobiami, ale nie tak výrazne ako z kartografických výstupov. V oboch sledovaných obdobiach nad inými typmi aktivity u užívateľa výrazne prevládal typ aktivity STILL. Pomerne často sa v oboch obdobiach vyskytoval aj typ aktivity WALKING. Výskyt iných typov aktivít bol oproti týmto dvom typom zanedbateľný. Počty bodov v priebehu jednotlivých dní boli v sledovanom období v roku 2019 pomerne rovnomerné len s menšími výkyvmi, v roku 2020 boli rozdiely v počte bodov medzi jednotlivými dňami podstatne väčšie a v období od 10. do 13. 11. sa na území Olomouca nevyskytol žiaden bodový záznam. Počet bodov v priebehu jednotlivých hodín nebol pandémiou významnejšie ovplyvnený, jediným výraznejším rozdielom medzi dvomi sledovanými obdobiami je, že v sledovanom období v roku 2019 bolo najviac bodov zaznamenaných o 18. hodine, zatiaľ čo o rok neskôr ich bolo najviac o 14. hodine. Bolo by ale ťažké hľadať súvislosť medzi pandémiou a touto zmenou denného maxima. Výskyt užívateľa v Olomouci v priebehu jednotlivých dní v týždni bol v sledovanom období v roku 2019 v podstate rovnomerný. V roku 2020 boli najnižšie počty bodov zaznamenané v čase od pondelka do stredy a najviac bodov bolo

zaznamenaných v piatky a počas víkendových dní. Mohlo to byť spôsobené tým, že od pondelka do stredy mal užívateľ dištančnú výuku a z toho dôvodu trávil väčšie množstvo času doma.

**Celkove** sa dá skonštatovať, že pandémia zmenila priestorové vzory pohybu Užívateľa 3 tým, že znížila jeho výskyt v škole a na miestach, kde predtým obvykle trávil voľný čas a súčasne zredukovala aj jeho celkovú mobilitu v rámci mesta. Predpoklad stanovený na začiatku podkapitoly bol teda potvrdený. Okrem toho všetky vizualizácie vytvorené z dát užívateľa naznačujú, že sa znížil jeho výskyt u rodičov a naopak zvýšil sa jeho výskyt u priateľky, čo sa však za dôsledok pandémie nedá považovať.

#### 5.2.4 Dáta Užívateľa 4

Pri pozorovaní vizualizácií výskytu užívateľa v okolí vybraných **bodov záujmu** (Príloha 21) si môžeme všimnúť, že podobne ako Užívateľ 3 mal v oboch sledovaných obdobiach miesto trvalého bydliska v Olomouci, pretože jeho výskyt v okolí tohto miesta bol v oboch obdobiach častejší než výskyt v okolí Katedry geoinformatiky. Predpoklad, že v období pandémie trávajú ľudia menšie množstvo času v škole a na pracovisku sa potvrdil len čiastočne, nakoľko na Katedre geoinformatiky síce v období v priebehu pandémie trávil menej času, ale viac času zato trávil na pracovisku v pizzerii. Podobne ako u Užívateľa 3 aj u Užívateľa 4 poklesol výskyt v OC Šantovka na úkor OC Globus. Výskyt užívateľa v OC Haná sa mierne zvýšil. Výrazný pokles sa dá pozorovať vo výskyte v okolí hlavného nádražia, čo sa dá vysvetliť tým, že užívateľ v priebehu pandémie menej cestoval vlakom. U tohto užívateľa nebol žiaden bod v meste stanovený ako miesto trávenia voľného času, pretože užívateľ uviedol, že vo voľnom čase sa väčšinou venuje geocachingu mimo územia mesta.

Podľa vizualizácií výskytu užívateľa v **mestských častiach** Olomouca (Príloha 22) sa jeho výskyt v jednotlivých častiach mesta v dvoch sledovaných obdobiach výraznejšie nezmenil. Z danej dvojice máp vôbec nevyplýva, že by sa mobilita užívateľa v rámci mesta v priebehu pandémie znížila a práve naopak sa zdá, že sa mierne zvýšila. Dalo by sa to vysvetliť tým, že užívateľ pracuje ako rozvážač pizze a v čase pandémie a zavretých reštaurácií sa záujem ľudí o donáškovú službu zvýšil. Objavuje sa tiež výskyt v Svatom Kopečku a Radíkove, teda v častiach mimo zastavaného územia mesta, čo sa dá vysvetliť tým, že užívateľ ako mnohí iní ľudia v čase pandémie častejšie chodil na prechádzky do prírody. V oboch sledovaných obdobiach sa užívateľ najčastejšie vyskytoval v Hejčine, teda v mestskej časti, kde je jeho trvalé bydlisko.

Z vizualizácií dát užívateľa agregovaných do **hexagonálnej siete** (Príloha 23) vyplýva, že najviac času v sledovanom období v roku 2019 trávil v mieste svojho trvalého bydliska a jeho okolí, na pracovisku a v jeho okolí a na Katedre geoinformatiky a v jej okolí. Najvýraznejším rozdielom vizualizácií z dvoch sledovaných období je, že vo vizualizácii z roku 2020 sa nedá pozorovať taký výrazný výskyt v okolí Katedry geoinformatiky a užívateľ sa taktiež menej vyskytoval na hlavnom nádraží. Na mapách z oboch období sa dá čiastočne identifikovať trasa z miesta bydliska do miesta práce.

Z vizualizácie upravených výsledkov nástroja **Collect Events** (Príloha 24) môžeme vidieť, že v sledovanom období v roku 2019 trávil užívateľ najviac času v mieste svojho trvalého bydliska, o niečo menej v práci a na Katedre geoinformatiky a jeho výskyt v iných lokalitách bol oproti tomu zanedbateľný. O rok neskôr trávil najviac času doma,

viac času než rok predtým trávil v práci a jeho výskyt v iných lokalitách bol oproti týmto dvom miestam zanedbateľný.

Na **mapách intenzity výskytu** užívateľa v Olomouci (Príloha 25) môžeme vidieť, že v sledovanom období v roku 2019 trávil najviac svojho času v mieste svojho bydliska, na Katedre geoinformatiky a v práci, často sa tiež vyskytoval na hlavnom nádraží, na Hornom námestí a na parkovisku na Dobrovského ulici (užívateľ to odôvodnil častou návštevou podniku v blízkosti parkoviska). Ako najčastejšia trasa sa z máp intenzity výskytu z obidvoch období javí byť trasa z práce domov s tým, že úsek na triede Svobody sa zdá byť o niečo frekventovanejší než zvyšok trasy. Na mape intenzity výskytu vytvorenej z dát zo sledovaného obdobia v roku 2020 sú miestami najčastejšieho výskytu bydlisko a pracovisko užívateľa.

Pri pohľade na **časové animácie** aktivity Užívateľa 4 v Olomouci v priebehu dvoch sledovaných období (Prílohy 45 a 46) sa nedá povedať, že by sa jeho celková mobilita pod vplyvom pandémie výraznejším spôsobom zmenila a zdá sa, že v jednom aj druhom období podnikal pomerne rozsiahle cesty po Olomouci.

Zaujímavé zistenia prinášajú aj grafy vytvorené z **kontingenčných tabuliek** vytvorených z dát Užívateľa 4 (Príloha 5). Najčastejším typom aktivity Užívateľa bol v oboch obdobiach STILL, po ktorom nasledovali typy aktivity IN VEHICLE a WALKING, pričom počet záznamov typu aktivity IN VEHICLE sa v druhom sledovanom období mierne zvýšil. To potvrdzuje hypotézu stanovenú pri analýze mapových výstupov, že sa užívateľ častejšie venoval rozvozu pizze. V grafoch vyjadrujúcich počet bodových záznamov v priebehu jednotlivých dní sa vyskytujú nepravidelné výkyvy, ktoré je ťažké nejakým spôsobom interpretovať. Výskyt užívateľa v Olomouci v priebehu jednotlivých dní v týždni bol v sledovanom období v roku 2019 pomerne rovnomerný, zatiaľ čo v sledovanom období v roku 2020 je možné pozorovať v piatky a soboty výrazne vyšší počet bodov oproti iným dňom. Predpoklad, že je to spôsobené častejším rozvozom pizze v týchto dňoch, Užívateľ 4 aj sám potvrdil. Počty bodových záznamov užívateľa v priebehu jednotlivých hodín sa v dvoch sledovaných obdobiach výraznejšie nelíšia. Najnižšie počty bodov boli v oboch prípadoch zaznamenané v nočných hodinách, smerom k obedu mierne narastali, poobede trochu klesli a následne začali opäť stúpať, pričom v neskorých večerných hodinách dosiahli svoje maximum.

**Celkove** sa dá skonštatovať, že stanovený predpoklad o vplyve pandémie na priestorové vzory osôb naplnil len čiastočne, keďže užívateľ síce počas pandémie trávil menšie množstvo času v škole, ale na pracovisku trávil viac času než predtým. Mobilita užívateľa v rámci mesta Olomouc tiež výrazne nepoklesla a z niektorých vizualizácií sa zdá, že práve naopak mierne vzrástla. Užívateľ to odôvodnil tým, že je to spôsobené častejším rozvozom pizze v druhom sledovanom období.

### 5.2.5 Zhrnutie výsledkov prípadovej štúdie

Celkove sa dá zhodnotiť, že predpoklad stanovený na začiatku podkapitoly, že pandémie má vplyv na priestorové vzory ľudí, ktorí v jej dôsledku trávajú väčšie množstvo času doma a menšie množstvo času na pracovisku, v škole, v reštauráciách, baroch a v iných miestach trávenia voľného času a súčasne je znížená aj ich celková mobilita, sa podarilo potvrdiť, hoci nie na 100%. Všetci užívatelia trávili menšie množstvo času v škole a v miestach trávenia voľného času, niektorí však trávili viac času v práci, čo sa u jedného užívateľa prejavilo aj zvýšením celkovej mobility. U niektorých sledovaných užívateľov spôsobili rozdiely v mobilite aj iné faktory, napríklad zmena miesta bydliska alebo väčšia pracovná vyťaženosť.

## 6 VÝSLEDKY

Táto kapitola prináša súhrn všetkých hmatateľných aj nehmatateľných výsledkov, ktoré boli v rámci práce vytvorené a ktoré sú dostupné buď priamo v texte práce alebo ako viazané či voľné prílohy. Výsledky neobsahujú skutočné mená osôb, ktoré dáta poskytli, ale poskytovateľom dát sú pridelené pseudonymy Užívateľ 1-6. Pseudonymy Užívateľ 1-4 sú pridelené študentom Katedry geoinformatiky, ktorí dáta pre účely práce poskytli, pseudonym Užívateľ 5 je pridelený autorovi práce a pseudonym Užívateľ 6 je pridelený zamestnancovi katedry, ktorý svoje dáta pre účely práce poskytol. Výstupy práce je možné rozdeliť na kartografické (mapy) a nekartografické (tabuľky, grafy a interpretácie výsledkov).

### 6.1 Kartografické výstupy práce

Kartografickým výsledkom práce je 20 tlačených máp vo formáte A4, 8 tlačených máp vo formáte A3, 8 časopriestorových animácií v digitálnej podobe.

**Analógové Mapy vo formáte A3** zobrazujú výsledky analýz dát šiestich užívateľov z obdobia od 22. 10. do 22. 11. 2019 pomocou testovaných metód dátovej analýzy v programe ArcGIS Pro 2.6.

Mapa *Miesta častého výskytu užívateľov v Olomouci od 22. 10. do 22. 11. 2019* (Príloha 26) obsahuje 6 mapových polí v mierke 1 : 50 000 zobrazujúcich dáta šiestich užívateľov agregované do hexagonálnej siete s dĺžkou hexagónu 100 metrov pomocou nástroja *Aggregate Points*.

Mapa *Výskyt užívateľov v mestských častiach Olomouca od 22. 10. do 22. 11. 2019* (Príloha 27) obsahuje 6 mapových polí v mierke 1: 150 000 zobrazujúcich počty bodových záznamov užívateľov na km<sup>2</sup> v mestských častiach Olomouca agregovaných pomocou nástroja *Spatial Join*.

Mapa *Výskyt užívateľov v okolí vybraných bodov záujmu v Olomouci od 22. 10. do 22. 11. 2019* (Príloha 28) obsahuje 6 mapových polí v mierke 1 : 50 000 zobrazujúcich počet bodových záznamov jednotlivých užívateľov v okruhu 100 metrov od bodov, ktoré boli stanovené ako ich body záujmu a kategorizované. Obalová zóna bodov s polomerom 100 metrov bola získaná pomocou nástroja *Buffer*, údaje o počte bodov boli získané pomocou nástroja *Spatial Join*.

Mapa *Intenzita výskytu užívateľov v Olomouci od 22. 10. do 22. 11. 2019* (Príloha 29) obsahuje 6 mapových polí v mierke 1 : 50 000 zobrazujúcich výsledok použitia nástroja *Calculate Density* na bodoví záznamy užívateľov.

Mapa *Miesta najčastejšieho výskytu užívateľov v Olomouci od 22. 10. do 22. 11. 2019* (Príloha 30) obsahuje 6 mapových polí v mierke 1 : 50 000 zobrazujúcich počet bodových záznamov užívateľov v lokalitách ich najčastejšieho výskytu. Výsledná podoba vizualizácií bola vytvorená z výsledkov nástroja *Collect Events* upravených pomocou nástrojov *Buffer*, *Dissolve Boundaries*, *Spatial Join* a *Feature to Point*.

Mapa *Zhluky bodových záznamov užívateľov v Olomouci od 22. 10. do 22. 11. 2019* (Príloha 31) obsahuje 6 mapových polí v mierke 1 : 50 000 zobrazujúcich zhluky bodových záznamov vytvorené pomocou nástroja *Find Point Clusters*.

Mapa *Významné miesta výskytu užívateľov v Olomouci od 22. 10. do 22. 11. 2019* (Príloha 32) obsahuje 6 mapových polí v mierke 1 : 50 000 zobrazujúcich miesta s vysokou istotou výskytu užívateľov podľa nástroja *Find Hot Spots*.

Mapa *Intenzita výskytu užívateľov v Olomouci od 22. 10. do 22. 11. 2019* (Príloha 33) obsahuje 6 mapových polí zobrazujúcich intenzitu výskytu užívateľov v mierke 1:50 000 vytvorených pomocou nástroja *Kernel Density*. Oblasti s hustotou bodových záznamov nižšou než 100 bodov na km<sup>2</sup> v mapách nie sú zobrazené.

**Analógové mapy vo formáte A4** zobrazujú výsledky tých metód analýzy dát, o ktorých sa rozhodlo, že majú dostatočnú výpovednú hodnotu na to, aby mohli byť interpretované a použité k analýze priestorových vzorov pohybu užívateľov a zmien týchto vzorov spôsobených pandemiou. Na rozdiel od máp vo formáte A3 sú vizualizované len dáta štyroch užívateľov, ktoré boli analyzované v rámci prípadovej štúdie. Mapy obsahujú vždy dve mapové polia, pričom jedno zobrazuje výsledok konkrétnej metódy analýzy dát zo sledovaného obdobia pred pandemiou, teda od 22. 10. do 22. 11. 2019 a druhé mapové pole zobrazuje výsledok zo sledovaného obdobia v priebehu pandémie, teda od 22. 10. do 22. 11. 2020. Mapy sú v mierke 1 : 40 000, s výnimkou máp výskytu užívateľov v mestských častiach Olomouca, ktorá je v mierke 1 : 200 000.

Mapy *Výskyt Užívateľa 1 – 4 v okolí vybraných bodov záujmu v Olomouci* (Príloha 6, 11, 16 a 21) obsahujú dve mapové polia zobrazujúce počet bodových záznamov jednotlivých užívateľov v okruhu 100 metrov od bodov stanovených ako ich body záujmu v dvoch sledovaných obdobiach. Obalová zóna bodov s polomerom 100 metrov bola získaná pomocou nástroja *Buffer*, údaje o počte bodov boli získané pomocou nástroja *Spatial Join*.

Mapy *Výskyt Užívateľa 1 – 4 v mestských častiach Olomouca* (Príloha 7, 12, 17 a 22) obsahujú dve mapové polia zobrazujúce počty bodových záznamov užívateľov na km<sup>2</sup> v mestských častiach Olomouca v dvoch sledovaných obdobiach. Údaje o počte bodov v mestských častiach boli získané pomocou nástroja *Spatial Join*.

Mapy *Miesta častého výskytu Užívateľa 1 – 4 v Olomouci* (Príloha 8, 13, 18 a 23) obsahujú dve mapové polia zobrazujúce počty bodových záznamov užívateľov v hexagonálnej sieti s dĺžkou hexagónu 100 m v dvoch sledovaných obdobiach. Bodové záznamy boli agregované do hexagonálnej siete pomocou nástroja *Aggregate Points*, hexagóny, ktoré obsahovali menej než 10 bodov, boli následne odfiltrované.

Mapy *Miesta najčastejšieho výskytu Užívateľa 1 – 4 v Olomouci* (Príloha 9, 14, 19 a 24) obsahujú dve mapové polia zobrazujúce počty bodových záznamov užívateľov v miestach ich najčastejšieho výskytu v dvoch sledovaných obdobiach. Vizualizácie boli vytvorené z výsledkov nástroja *Collect Events* upravených pomocou nástrojov *Buffer*, *Dissolve Boundaries*, *Spatial Join* a *Feature to Point*.

Mapy *Intenzita výskytu Užívateľa 1 – 4 v Olomouci* (Prílohy 10, 15, 20 a 25) obsahujú dve mapové polia zobrazujúce intenzitu výskytu užívateľov pomocou výsledku nástroja *Kernel Density*. Oblasti s hustotou bodových záznamov nižšou než 100 bodov na km<sup>2</sup> v mapách nie sú zobrazené.

**Digitálne animované mapy** sú výstupom z programu QGIS 3.18 a na ich tvorbu bol použitý plugin *Temporal Controller*. Mapy zobrazujú záznamy Užívateľov 1–4 z Google Location v priebehu jednotlivých dní v sledovaných obdobiach od 22. 10. do 22. 11. 2019 a od 22. 10. do 22. 11. 2020. Záznam z jedného dňa sa animácii zobrazuje jednu sekundu. Kompozičné prvky boli do animácií pridané ako dekorácie, dátum v nadpisoch je pohyblivý. Mapy sú dostupné ako prílohy 39 – 46 na priloženej SD karte v zložke *Animacie*.

## 6.2 Nekartografické výstupy práce

Medzi nekartografické výstupy práce patria tabuľky a grafy vytvorené autorom, ktoré sú dostupné ako voľné prílohy. Z výstup práce sa dá rovnako považovať aj autorova interpretácia výstupov, ktorej cieľom bolo porovnať zmeny priestorových vzorov a celkovej mobility osôb v Olomouci spôsobené pandemiou COVID-19.

**Tabuľkový prehľad existujúcich štúdií**, ktorý je dostupný ako Príloha 34, poskytuje prehľad o tom, aké odborné štúdie sa v minulosti zaoberali rôznymi formami mobilného zberu dát alebo analýzy priestorových vzorov. Je doplnkom kapitoly 3, ktorého cieľom hľadať spoločné a odlišné znaky publikácií, ktoré si autor v rámci rešerše našťudoval, s jeho vlastnou prácou. V tabuľkovom prehľade sú uvedené aj práce, ktoré nie sú v kapitole 3 podrobnejšie popísané, pretože bolo v priebehu ich štúdia zistené, že so zameraním tejto diplomovej práce majú len malú súvislosť.

**Tabuľkový prehľad metód analýzy dát Google Location** je dostupný ako Príloha 1. Jeho cieľom je stručne zosumarizovať výhody a nevýhody jednotlivých metód analýzy dát Google Location, ktoré boli v práci otestované. Podrobnejšie informácie o jednotlivých metódach a spôsoboch, akými boli na dátach testované, sú k dispozícii v kapitole 4.

**Dotazníky Užívateľov 1–4** s autorovým komentárom sú k dispozícii ako Prílohy 35–38. Obsahujú informácie o činnostiach vykonávaných v priebehu prvého týždňa zberu dát v druhom sledovanom období, ktoré si do dotazníka v Google Tabuľkách študenti zapisovali. K dotazníkom stiahnutým vo formáte XLSX bol pridaný komentár, ktorý sa snaží potvrdiť alebo vyvrátiť zhodnosť uvedených údajov so záznamom z Google Location.

**Kontingenčné tabuľky** vytvorené z dátových záznamov Užívateľov 1–4 z oboch sledovaných období sú k dispozícii na SD karte v zložke *KontingencneTabulky* a grafy z nich vytvorené sú k dispozícii ako viazané prílohy 2–5. Súbor vo formáte XLSX obsahuje list s atribútovou tabuľkou zdrojového dátového záznamu a 4 listy s kontingenčnými tabuľkami a grafmi z nich vytvorenými. List *TypAktivity* obsahuje informácie o počte záznamov vybraných typov aktivity v sledovanom období. List *Datum* obsahuje informácie o počte bodov v zázname v priebehu jednotlivých dní sledovaného obdobia. List *DenVTyzdni* obsahuje informácie o priemerných počtoch záznamov v priebehu jednotlivých dní v týždni v sledovanom období. List *Hodina* obsahuje informácie o počte záznamov v priebehu jednotlivých hodín v sledovanom období.

Veľmi dôležitým výstupom práce, ktorého vytvorenie vyplýva ako povinnosť už zo samotného zadania práce, je **interpretácia výsledkov** analýz v geografických informačných systémoch a v programe MS Excel, ktorej cieľom bolo zistiť, ako veľmi zmenila pandémia COVID-19 priestorové vzory pohybu vybraných osôb v Olomouci. Podarilo sa potvrdiť stanovený predpoklad, že v priebehu pandémie trávia ľudia väčšie množstvo času doma a menej času trávia v reštauráciách, baroch a v iných lokalitách bežného trávenia voľného času. Čiastočne sa potvrdilo aj menšie množstvo času stráveného na pracovisku, aj keď nie u všetkých užívateľov. Celková mobilita bola znížená len u troch zo štyroch užívateľov.

## 7 DISKUSIA

Diplomová práca Analýza priestorových vzorov pohybu vybraných osôb v Olomouci na základe dát Google Location sa snaží analyzovať priestorové a časové vzory pohybu osôb v Olomouci v dvoch sledovaných obdobiach s dôrazom na pozorovanie zmien najčastejšie navštívených miest, najčastejších trás a celkovej mobility vybraných užívateľov spôsobených pandemiou COVID-19.

Práca nadväzuje na autorovu bakalársku prácu autora, ktorej cieľom bolo otestovať možnosti využitia dát služby Google Location pre časopriestorové analýzy pohybu osôb. V bakalárskej práci sa autor zameriaval na konverziu dát, konvertované záznamy rôznymi spôsobmi štatisticky analyzoval, čím získal lepšiu predstavu o ich štruktúre a pomohlo mu to vytvoriť vhodný postup spracovania dát, ktorý aplikoval aj v diplomovej práci. Vizualizácie vytvorené v rámci bakalárskej práce sa dajú považovať za experimentálne, pretože autor pred písaním práce nemal žiadne vedomosti o vizualizácii podobného typu dát. Naproti tomu pri tvorbe diplomovej práce už autor mal skúsenosti so spracovaním takéhoto typu dát, ktoré si ešte rozšíril štúdiom ďalšej odbornej literatúry a tak sa mohol sústrediť na otestovanie širšieho spektra analýz a taktiež na vytvorenie prípadovej štúdie využívajúcej dáta Google Location.

Zadanie práce bolo vytvorené ešte pred prepuknutím pandémie a autor ani vedúci práce nepočítali so všetkými obmedzeniami, ktoré pandémia spôsobí. Pôvodným plánom bol dvojmesačný výskum v spolupráci s Magistrátom mesta Olomouc, ktorého cieľom malo byť otestovanie efektivity kombinovaných cestovných lístkov na MHD a Rekola. Výskum, ktorý mal prebiehať dva mesiace cca od 15. marca do 15. mája 2020, nebol uskutočnený a namiesto toho bol vytvorený alternatívny plán výskumu zmien mobility vybraných osôb v Olomouci v dôsledku pandémie.

Malé množstvo účastníkov výskumu bolo spôsobené tým, že v čase pandémie sa len malé množstvo potenciálnych respondentov, t. j. študentov Katedry geoinformatiky, zdržiavalo v Olomouci a aj z tých, ktorí tam v sledovanom období v roku 2020 boli, bolo len málo ochotných svoje dáta pre účely práce poskytnúť. Autor sa snažil malé množstvo dát vykompenzovať tým, že dáta, ktoré mal k dispozícii, analyzoval do hĺbky. Vyskúšal na nich rozličné typy analýz, pričom v texte práce uviedol aj informácie o parametroch, ktoré pri spúšťaní analytických nástrojov v geografických informačných systémoch nastavoval a uviedol, ktoré metódy sa javia ako vhodnejšie a ktoré ako menej vhodné pre analýzu dát Google Location. Táto práca môže teda slúžiť ako inšpirácia pre ľudí, ktorí by mali k dispozícii väčšie množstvo dát z tejto služby, ale menšie skúsenosti s ich spracovaním. Malé množstvo respondentov tiež umožnilo vypracovať detailnú analýzu porovnávajúcu priestorové a časové vzorov v dvoch sledovaných obdobiach zvlášť pre každého účastníka výskumu.

V práci boli z dôvodu malého množstva poskytnutých dát analyzované individuálne priestorové vzory pohybu jednotlivcov. V prípade, že by mal autor k dispozícii dáta od väčšej skupiny užívateľov, bolo by možné vytvoriť analýzy skupinových priestorových vzorov buď všetkých respondentov alebo respondentov klasifikovaných do skupín napríklad na základe ich veku či zamestnania. Výsledky takýchto analýz by mohli byť poskytnuté aj rôznym administratívnym inštitúciám, napríklad magistrátu mesta.

Problémom dát Google Location je, že obsahujú veľké množstvo osobných informácií a aj to bolo dôvodom, prečo ich bolo ochotných poskytnúť také malé množstvo ľudí. Dáta boli v práci síce anonymizované, no samotný autor mená užívateľov poznal.



V prípade spracovania väčšieho množstva dát by riešením mohol byť formulár, do ktorého by užívatelia svoje dáta nahrali bez nutnosti uvedenia mena a priezviska.

Validácia dát Google Location podľa dát z dotazníkov ukázala, že typom aktivity uvedeným v dotazníkoch väčšinou nezodpovedalo príliš veľké množstvo bodov v zázname z Google Location a to najmä z dôvodu, že väčšine záznamov sa nedal priradiť žiaden typ aktivity. V interpretácii dát v prípadovej štúdii sa u jedného užívateľa objavili prípady, keď boli niektoré miesta častého výskytu nesprávne identifikované a vysoký počet bodových záznamov v týchto miestach sa nepodarilo úplne objasniť. Odhalené nepresnosti však nemajú vplyv na názor autora, že dáta Google Location majú v analýze priestorových vzorov veľký potenciál.

Metóda vytvorenia časopriestorovej kocky zo spracovávaných dát má podľa autora veľký potenciál, ale z výsledku tejto metódy spracovania dát sa mu nepodarilo vytvoriť kartografickú vizualizáciu. Informácie, ktoré o svojich skúsenostiach s jej vytváraním v programe ArcGIS Pro vo práci poskytol, môžu slúžiť ako základ ďalším ľuďom, ktorí sa budú venovať analýze dát Google Location a budú schopní vytvoriť z výsledkov metódy zmysluplnú kartografickú vizualizáciu.

V zadaní práce sa spomína aj prípadné vytvorenie nástroja umožňujúceho automatizované spracovanie dát. Nástroj napokon v práci vytvorený nebol, pretože sa nenašla jedna metóda, ktorá by bola na spracovanie dát Google Location ideálna, ale väčšie množstvo metód, ktoré môžu byť na spracovanie týchto dát vhodné a ich výber závisí od toho, aké informácie chce užívateľ z dát získať.

Pandémia COVID-19 stále trvá a je ťažké predpokladať, ako dlho ešte trvať bude, z čoho logicky vyplýva, že bude vytvorené ešte množstvo štúdií zaoberajúcich sa priestorovými vzormi ľudskej mobility v čase pandémie a ich zmenami spôsobenými zavádzaním rôznych protipandemických opatrení. Táto diplomová práca môže slúžiť ako zdroj informácií pre ďalšie práce, ktoré sa budú zapodievať podobnou problematikou.

## 8 ZÁVER

Hlavným cieľom diplomovej práce bolo analyzovať zmeny priestorových vzorov pohybu vybraných osôb v Olomouci spôsobené pandemiou COVID-19 s použitím dátových záznamov z Google Location. Práca nadväzuje na autorovu bakalársku prácu, ktorej cieľom bolo otestovať možnosti využitia dát služby Google Location pre časopriestorové analýzy pohybu osôb.

Na začiatku práce autor v stručnosti popisuje použité metódy analýzy dát, použité programy a dáta a postup spracovania témy práce.

Ďalej autor predstavuje poznatky, ktoré získal pri štúdiu odbornej literatúry súvisiacej s témou práce. V rešerši autor začína zisteniami z publikácií venujúcich sa pojmu priestorový vzor, na základe ktorých si vytvára svoju vlastnú definíciu, pokračuje zisteniami z prác, ktoré sa venovali analýze dát služby Google Location, ďalej sa venuje prácam analyzujúcimi mobilitu osôb v mestskom prostredí a na záver popisuje práce skúmajúce zmeny mobility v dôsledku pandémie. Samotná rešerš je doplnená tabuľkovým prehľadom (Príloha 34), ktorý v schematickej forme prináša informácie o vzájomných rozdieloch a podobnostiach naštudovaných publikácií.

Nasleduje praktická časť práce, v ktorej sa autor na začiatku zameriava na testovanie rôznych metód analýzy dát s cieľom zistiť, ktoré z nich budú najviac použiteľné pre účely analýzy a dát Google Location. Metódy sú testované nad dátami, ktoré autorovi poskytli 4 študenti a jeden zamestnanec Katedry geoinformatiky a nad dátami autora samotného. Najprv je sú popísané metódy analýzy dát v programe ArcGIS Pro 2.6. Z výsledkov testovania všetkých metód nad dátami šiestich užívateľov boli vytvorené analógové mapy vo formáte A3, ktoré porovnávajú výsledky týchto metód u jednotlivých užívateľov. Metódami, ktoré sa ukázali ako najvhodnejšie na analýzu dát z Google Location, boli agregácia bodových záznamov na administratívne jednotky (mestské časti Olomouca), agregácia bodových záznamov do hexagonálnej siete, vizualizácia množstva bodových záznamov v okruhu 100 m od vybraných bodov záujmu užívateľov, určenie miest najčastejšieho výskytu pomocou upraveného výsledku nástroja *Collect Events* a vytvorenie mapy intenzity výskytu užívateľov pomocou nástroja *Kernel Density*. Z výsledkov týchto metód sú vytvorené aj vizualizácie vo formáte A4, ktoré porovnávajú výsledky analýz dát štyroch študentov Katedry geoinformatiky z dvoch sledovaných období, z ktorých jedno bolo ešte pred pandemiou, konkrétne od 22. 10. do 22. 11. 2019 a druhé v priebehu pandémie, konkrétne od 22. 10. do 22. 11. 2020. Hoci aj autor sám je študentom, jeho výsledky analýz jeho dát neboli týmto spôsobom vizualizované, nakoľko sa v druhom sledovanom období v Olomouci vôbec nevyskytoval.

Následne je v práci popísaný postup vytvorenia časovej animácie v programe QGIS 3.18. Boli vytvorené časové animácie z dát štyroch študentov z dvoch vyššie spomínaných sledovaných časových období. Keďže autor usúdil, že vytvorené animácie majú dostatočnú výpovednú hodnotu, sú použité v prípadovej štúdií s cieľom poukázať na zmeny časových vzorov pohybu užívateľov.

Z dát štyroch užívateľov z dvoch časových období sú vytvorené aj kontingenčné tabuľky, ktoré dobre vypovedajú o zmenách časových vzorov užívateľov aj o počtoch jednotlivých typov aktivity v zázname, preto je rozhodnuté použiť aj ich výsledky v prípadovej štúdií.

Ďalej sú v praktickej časti dátové záznamy štyroch študentov validované podľa dát z dotazníka, do ktorého si študenti počas týždenného obdobia v priebehu zberu dát

zapisovali svoje aktivity. Autor sa sústreďí na porovnávanie typov aktivity zapísaných v dotazníku s typmi aktivity určenými podľa záznamu z Google Location a vo výsledku zisťuje, že väčšinou len malé množstvo bodov v zázname z Google Location zodpovedalo typom aktivity určeným v dotazníku.

Nasleduje už spomínaná prípadová štúdia, ktorej cieľom je na základe výsledkov analýz a z nich vytvorených vizualizácií overiť stanovený predpoklad, že v priebehu pandémie trávajú ľudia väčšie množstvo času doma a menej času trávajú na pracovisku, v škole či v miestach ich obvyklého trávenia voľného času. Predpoklad sa podarí overiť len čiastočne, keďže u niektorých užívateľov boli najčastejšie trasy, celková mobilita a najčastejšie navštívené miesta ovplyvnené aj inými faktormi, ktoré s pandemiou nesúviseli.

Kapitola Výsledky v stručnosti popisuje výsledky, pričom ich delí na výsledky kartografické, kam zaraďuje vytvorené analógové mapy a digitálne časové animácie a výsledky nekartografické, kam zaraďuje vytvorené tabuľky a grafy a taktiež slovnú interpretáciu výsledkov práce, ktorá porovnávala mobilitu vybraných osôb v Olomouci pred pandemiou a v jej priebehu.

## POUŽITÁ LITERATÚRA A INFORMAČNÉ ZDROJE

ALLAHVIRANLOO, M.; RECKER, W. (2015). Mining activity pattern trajectories and allocating activities in the network. *Transportation*, 42(4), s. 561–579. ISSN: 0041-1612

Andrienko, N., Andrienko, G., Miksch, S., Schumann, H. a Wrobel, S., 2021. A theoretical model for pattern discovery in visual analytics. *Visual Informatics*, 5(1), s. 23–42. ISSN: 2468-502X

*ArcGIS Pro* [online]. 2021 [cit. 2021-07-26]. ArcGIS Pro geoprocessing tool reference. Dostupné z WWW: < <https://pro.arcgis.com/en/pro-app/latest/tool-reference/main/arcgis-pro-tool-reference.htm> >

BOATES, I. *GitHub* [online]. 2019 [cit. 2019-03-17]. android\_location\_converter. Dostupné z WWW: < [https://github.com/iboates/android\\_location\\_converter](https://github.com/iboates/android_location_converter) >

BONGIORNO, Christian; SANTUCCI, Daniele; KON, Fabio a kol., 2019. Comparing bicycling and pedestrian mobility: Patterns of non-motorized human mobility in Greater Boston. *Journal of Transport Geography*. 2019, 10, 80. ISSN: 0966-6923

Burian, J., Zajíčková, 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), 83. ISSN: 2076-0760

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

FUSKOVÁ, Dana. *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/> >

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*, s. 330–339. New York, New York, USA: ACM Press. ISBN: 978-1-59593-609-7

GUDMUNDSSON, Joachim, Patrick LAUBE a Thomas WOLLE, 2017. Movement Patterns in Spatio-Temporal Data. In: *Encyclopedia of GIS. B.m.: Springer International Publishing*, s. 1362–1370. ISBN: 978-3-319-17884-4

HOU, Yuting; ADITHI, Moogoor, 2019. Spatial analysis of older adults' travel behaviour in Singapore. In: *Urban Environments for Healthy Ageing*. B.m.: Routledge, 2019 s. 117–145. ISBN: 9780429243097

CHOW, T. Edwin; Choi, Yusik; Yang, Mei; Mills, David; YUE Ricci, 2021. Geographic pattern of human mobility and COVID-19 before and after Hubei lockdown, *Annals of GIS*, 2, 7. s. 127-138. ISSN: 1947-5683

JARCOVJÁK, David. *Bakalárska práca: David Jarcovják* [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/>>

*kepler.gl* [online]. 2021 [cit. 2021-07-26]. User guides. Dostupné z WWW: < <https://docs.kepler.gl/docs/user-guides>>

KRUMM, J. and HORVITZ, E. (2006). Predestination: Inferring Destinations from Partial Trajectories. *The Eighth International Conference on Ubiquitous Computing*, s. 243–260. ISBN: 978-3-540-39634-5

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), s. 249–265. ISSN: 1749-6632

LÖCHTEFELD, M., 2019. Detournavigator - Using google location history to generate unfamiliar personal routes. *Conference on Human Factors in Computing Systems - Proceedings*. 1–6.

MI KYEONG, Kim; SANGPIL, Kim ; HONG GYOO, Sohn, 2018. Relationship between Spatio-Temporal travel patterns derived from smart-card data and local environmental characteristics of Seoul, Korea. *Sustainability (Switzerland)*. 2018, 10(3). ISSN: 2071-1050.

MUSAKWA, Walter; M. SELALA, Kadibetso, 2016. Mapping cycling patterns and trends using Strava Metro data in the city of Johannesburg, South Africa. *Data in Brief*. 2016, 9. s. 898-905. ISSN: 2352-3409

NASERIAN, E., WANG, X., DAHAL, K., WANG, Z.; WANG, Z. (2018). Personalized location prediction for group travellers from spatial-temporal trajectories. *Future Generation Computer Systems*, 83, s. 278–292. ISSN 0167-739X

NASUTION, Muhammad I. P.; SAMSUDIN, Samsudin, 2018. Using google location APIs to find an accurate criminal accident Location. *International Journal of Engineering & Technology*. 2018, 7(3). s. 1818–1820. ISSN: 2227-524X

NOVÁK, Jakub; TEMELOVÁ, Jana, 2012. Každodenní život a prostorová mobilita mladých Pražanů: pilotní studie využití lokalizačních dat mobilních telefonů. *Sociologický Časopis / Czech Sociological Review*. 2012, Vol. 48, No. 5, s. 911–938. ISSN: 00380288.

PÁSZTO, Vít; BURIAN, Jaroslav; MACKŮ, Karel, 2021. Changing Mobility Lifestyle: A Case Study on the Impact of COVID-19 Using Personal Google Locations Data. *International Journal of E-Planning Research*. 2021, 2, 10. ISSN:2160-9918

PATT, T. *GitHub* [online]. 2021 [cit 2021-07-26]. location-history-visualizer. Dostupné z WWW: < <https://github.com/theopolisme/location-history-visualizer> >

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> >

RODRIGUEZ, Macarulla A.; TIBERIUS, C.; VAN BREE, R. ; GERADTS, Z., 2018. Google timeline accuracy assessment and error prediction. *Forensic Sciences Research*, 3(3), s.240-255. ISSN: 2096-1790

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/> >

RUKTANONCHAI, Nick Warren; RUKTANONCHAI Corrine Warren, FLOYD Jessica Rhona; J. TATEM Andrew, 2018. Using Google Location History data to quantify fine-scale human mobility. *International Journal of Health Geographics*. B.m.: BioMed Central, 17(1), 1–13. ISSN 1476072X.

RYBNIKÁR, Ľ. *Bakalárska práca: Ľuboš Rybnikár* [online]. 2019 [cit. 2020-01-03]. Analýza a vizualizácia dát služby Google Location. Dostupné z WWW: < <https://www.geoinformatics.upol.cz/dprace/bakalarske/rybnikar19/> >

SALOMÓN, S., TÍRNĀUCĀ, C., DUQUE, R., MONTAÑA, J.L. (2017). Daily Routines Inference Based on Location History. *Ubiquitous Computing and Ambient Intelligence*, pp.828-839. ISBN: 978-3-319-67585-5

SHARMEEN, Naila; HOUSTON, Douglas, 2019. Spatial Characteristics and Activity Space Pattern Analysis of Dhaka City, Bangladesh. *Urban Science*. 2019, 3(1), 36. ISSN 2413-8851.

SOHN, T.; VARSHAVSKY, A.; LAMARCA, A.; Y. CHEN, M. a kol., 2006. Mobility Detection Using Everyday GSM Traces. (2006). *Ubiquitous Computing*, s. 212–224. Springer, Berlin, Heidelberg. doi:10.1007/11853565\_13.

SOUKUP, Jan, 2017. Co nám prozradí data z mobilů? *Arc Revue*. 2017, 25, 2, s. 10 - 13. ISSN 1211-2135.

ŠVEDA, Martin; BARLÍK, Peter, PODOLÁK, Peter, 2019. Koľko ľudí býva v zázemí Bratislavy? Odhad populačnej veľkosti obcí v zázemí Bratislavy s využitím lokalizačných údajov mobilnej siete, In: ŠVEDA, Martin; ŠUŠKA, Pavel (ed.). *Suburbanizácia. Ako sa mení zázemie Bratislavy?* Bratislava : Geografický ústav SAV, 2019. s. 184 - 205. ISBN: 978-80-89548-08-8.

THUDT, A., BAUR, D.; CARPENDALE, S., 2013. Visits: A Spatiotemporal Visualization of Location Histories. *Eurographics Conference on Visualization (EuroVis) (2013)*, s. 1–5.

TOGER, M.; KOURTIT, K.; NIJKAMP, P.; ÖSTH, J., 2021. Mobility during the COVID-19 Pandemic: A Data-Driven Time-Geographic Analysis of Health-Induced Mobility Changes. *Sustainability*. 2021, 13, 4027. s. 127–138. ISSN: 2071-1050

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, s. 141–155. ISSN: 2214367X

YE, Y., ZHENG, Y., CHEN, Y., FENG, J.; XIE, X., 2009. Mining Individual Life Pattern Based on Location History. *Tenth International Conference on Mobile Data Management: Systems*, s.1–10. ISBN: 978-0-7695-3650-7

ZDĚRADIČKA, Marek, 2016. Využití lokalizačních dat mobilních operátorů pro městské plánování. In *Konference GIS Esri v ČR : Sborník příspěvků*. Praha: Kongresové centrum Praha, 2016. s. 39. ISBN 978-80-905316-4-2.

## **PRÍLOHY**



# ZOZNAM PRÍLOH

## Viazané prílohy:

- Príloha 1 Prehľad testovaných metód analýzy dát
- Príloha 2 Grafy vytvorené z kontingenčných tabuliek Užívateľa 1
- Príloha 3 Grafy vytvorené z kontingenčných tabuliek Užívateľa 2
- Príloha 4 Grafy vytvorené z kontingenčných tabuliek Užívateľa 3
- Príloha 5 Grafy vytvorené z kontingenčných tabuliek Užívateľa 4
- Príloha 6 Výskyt Užívateľa 1 v okolí vybraných bodov záujmu v Olomouci
- Príloha 7 Výskyt Užívateľa 1 v mestských častiach Olomouca
- Príloha 8 Miesta častého výskytu Užívateľa 1 v Olomouci
- Príloha 9 Miesta najčastejšieho výskytu Užívateľa 1 v Olomouci
- Príloha 10 Intenzita výskytu Užívateľa 1 v Olomouci
- Príloha 11 Výskyt Užívateľa 2 v okolí vybraných bodov záujmu v Olomouci
- Príloha 12 Výskyt Užívateľa 2 v mestských častiach Olomouca
- Príloha 13 Miesta častého výskytu Užívateľa 2 v Olomouci
- Príloha 14 Miesta najčastejšieho výskytu Užívateľa 2 v Olomouci
- Príloha 15 Intenzita výskytu Užívateľa 2 v Olomouci
- Príloha 16 Výskyt Užívateľa 3 v okolí vybraných bodov záujmu v Olomouci
- Príloha 17 Výskyt Užívateľa 3 v mestských častiach Olomouca
- Príloha 18 Miesta častého výskytu Užívateľa 3 v Olomouci
- Príloha 19 Miesta najčastejšieho výskytu Užívateľa 3 v Olomouci
- Príloha 20 Intenzita výskytu Užívateľa 3 v Olomouci
- Príloha 21 Výskyt Užívateľa 4 v okolí vybraných bodov záujmu v Olomouci
- Príloha 22 Výskyt Užívateľa 4 v mestských častiach Olomouca
- Príloha 23 Miesta častého výskytu Užívateľa 4 v Olomouci
- Príloha 24 Miesta najčastejšieho výskytu Užívateľa 4 v Olomouci
- Príloha 25 Intenzita výskytu Užívateľa 4 v Olomouci

## Voľné prílohy

- Príloha 26 Miesta častého výskytu užívateľov v Olomouci
- Príloha 27 Výskyt užívateľov v mestských častiach Olomouca
- Príloha 28 Výskyt užívateľov v okolí vybraných bodov záujmu v Olomouci
- Príloha 29 Intenzita výskytu Užívateľov v Olomouci (Calculate Density)
- Príloha 30 Miesta najčastejšieho výskytu užívateľov v Olomouci
- Príloha 31 Zhluky bodových záznamov užívateľov v Olomouci
- Príloha 32 Významné miesta výskytu užívateľov v Olomouci
- Príloha 33 Intenzita výskytu Užívateľov v Olomouci (Kernel Density)
- Príloha 34 Tabuľkový prehľad existujúcich štúdií
- Príloha 35 Dotazník Užívateľa 1 s komentárom
- Príloha 36 Dotazník Užívateľa 2 s komentárom
- Príloha 37 Dotazník Užívateľa 3 s komentárom
- Príloha 38 Dotazník Užívateľa 4 s komentárom

Príloha 39	Aktivita Užívateľa 1 v Olomouci v čase od 22. 10. do 22. 11. 2019
Príloha 40	Aktivita Užívateľa 1 v Olomouci v čase od 22. 10. do 22. 11. 2020
Príloha 41	Aktivita Užívateľa 2 v Olomouci v čase od 22. 10. do 22. 11. 2019
Príloha 42	Aktivita Užívateľa 2 v Olomouci v čase od 22. 10. do 22. 11. 2020
Príloha 43	Aktivita Užívateľa 3 v Olomouci v čase od 22. 10. do 22. 11. 2019
Príloha 44	Aktivita Užívateľa 3 v Olomouci v čase od 22. 10. do 22. 11. 2020
Príloha 45	Aktivita Užívateľa 4 v Olomouci v čase od 22. 10. do 22. 11. 2019
Príloha 46	Aktivita Užívateľa 4 v Olomouci v čase od 22. 10. do 22. 11. 2020
Príloha 47	Poster
Príloha 48	SD karta

### **Popis štruktúry SD**

Adresáre:

- Animacie (animácie vytvorené z dát)
- Dotazníky (dotazníky Užívateľov 1–4 s autorovým komentárom)
- KontingencneTabulky (Kontingenčné tabuľky a grafy z nich vytvorené)
- Poster
- Projekty (Mapové projekty obsahujúce výsledky prevedených analýz)
- Python (Skript na konverziu dát z Google Location)
- Resers (Prehľad existujúcich štúdií)
- TextPrace
- WEB



Príloha 1 – Prehľad testovaných metód analýzy dát

Softvér	Metóda analýzy dát	Výhody	Nevýhody
ArcGIS Pro 2.6	Agregácia bodov do polygónov (s použitím nástroja <b>Aggregate Points</b> , prípadne <b>Spatial Join</b> )	Vhodné na štatistické účely	Aby výsledok nebol zavádzajúci, je potrebná normalizácia na rozlohu polygónov
	Agregácia do hexagonálnej siete (nástroj <b>Aggregate Points</b> , resp. kombinácia nástrojov <b>Generate Tesselation</b> a <b>Spatial Join</b> )	Pomáha pri identifikácii miest častého výskytu.	Výsledok obsahuje množstvo hexagónov, v ktorých sa daná osoba vyskytovala len výnimočne
	Výskyt v okolí bodov záujmu ( <b>Buffer+Spatial Join</b> )	Vhodné pri porovnávaní výskytu osôb vo vybraných lokalitách v rôznych obdobiach.	Výber bodov záujmu je subjektívny. Stráca sa informácia o celkovej mobilite v rámci mesta.
	Nástroj <b>Calculate Density</b>	Pomáha pri identifikácii najčastejšie navštevovaných miest a oblastí.	Výsledok je esteticky nepríťažlivý a skresľujúci
	Nástroj <b>Collect Events</b>	Vhodné na zistenie najčastejšie navštívených lokalít	Chýba možnosť nastavenia vstupných parametrov, body majú vysokú hodnotu COUNT len v prípade, že súradnice bodov v pôvodnej vrstve sú identické
	Nástroj <b>Find Hot Spots</b>	Vizualizácia oblastí s vysokou pravdepodobnosťou výskytu užívateľa	Metóda sa ukázala ako nevhodná na analýzu dát z Google Location.
	Nástroj <b>Find Point Clusters</b>	Výsledok je po vizuálnej stránke príťažlivý	Väčšinou je ťažké nájsť zmysel v zhlukoch bodov vytvorených nástrojom
	Nástroj <b>Kernel Density</b>	Tvorba heatmáp s možnosťou nastavenia parametrov a symbológie	Výpovedná hodnota výsledku vo veľkom závisí od správneho nastavenia symbológie
	<b>Space Time Cube</b>	Vizualizácia s použitím času ako tretieho rozmeru dát	Problematická tvorba kartografických výstupov

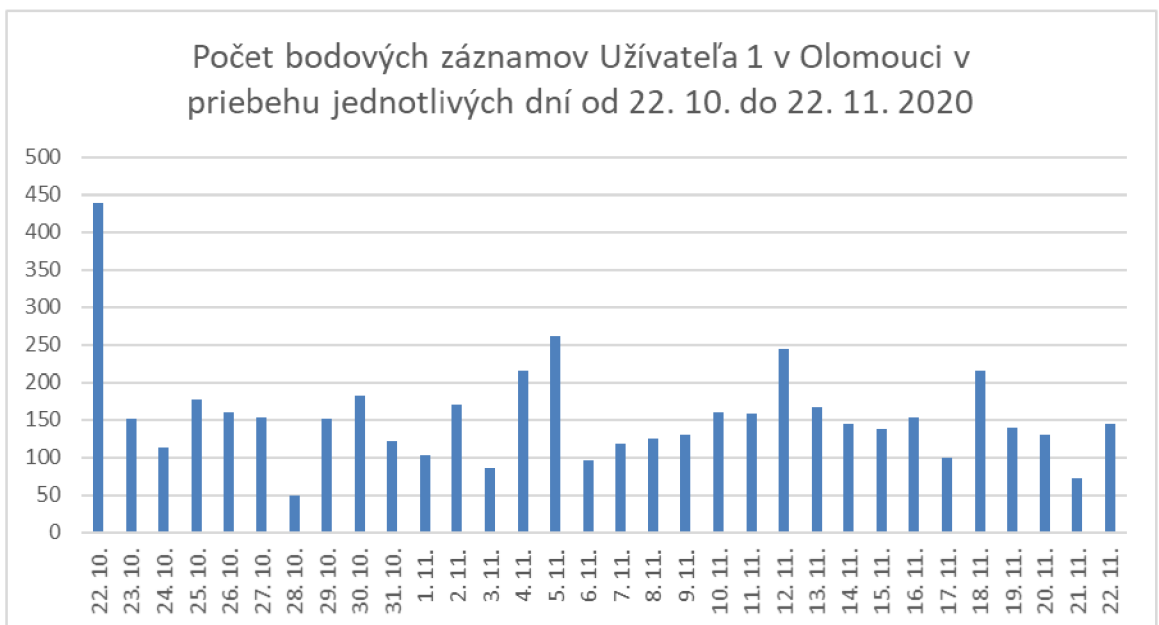

Príloha 1 – Prehľad testovaných metód analýzy dát

Softvér	Metóda analýzy dát	Výhody	Nevýhody
QGIS 3.18	Temporal Controller	Možnosť vytvorenia zaujímavých časových animácií	Problematické pridávanie kompozičných prvkov do výstupu
MS Excel 2016	Kontingenčné tabuľky a grafy	Vhodné pri hľadaní časových vzorov pohybu osôb a ich zmien	Boli použité dáta z krátkeho časového obdobia, pri použití dát z dlhšieho obdobia by výsledky mohli byť ešte zaujímavejšie

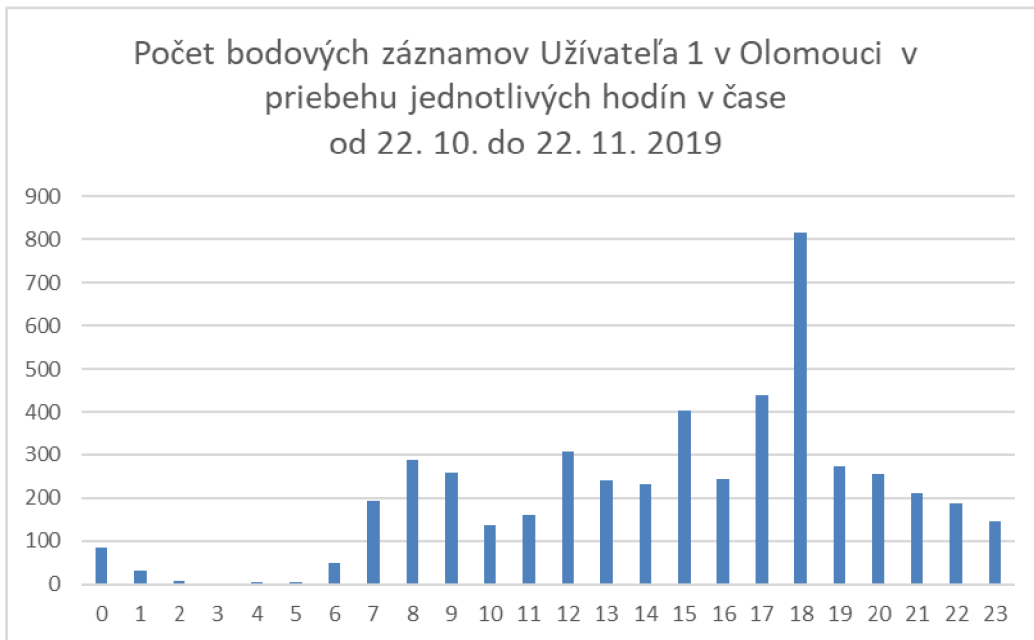

Príloha 2 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 1




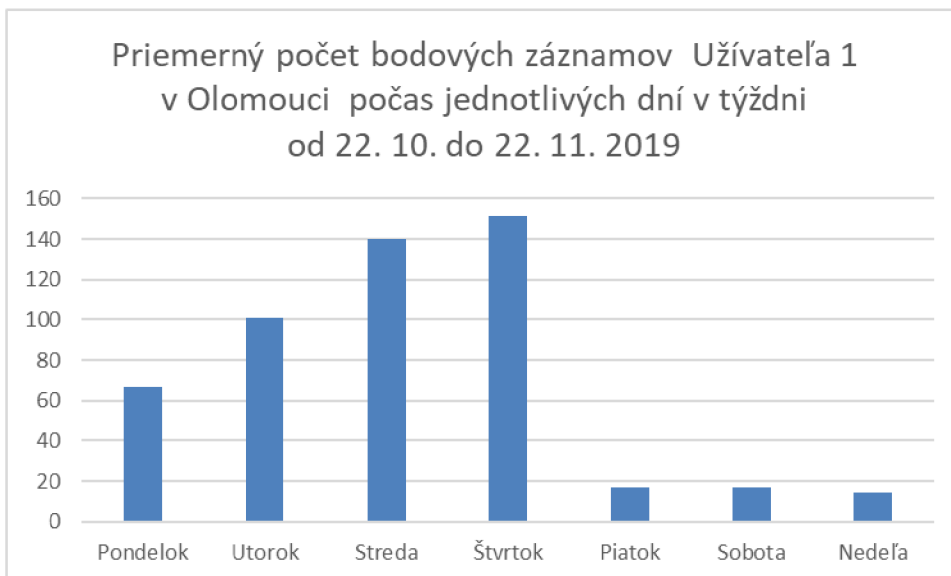
Príloha 2 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 1



Príloha 2 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 1





Príloha 2 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 1







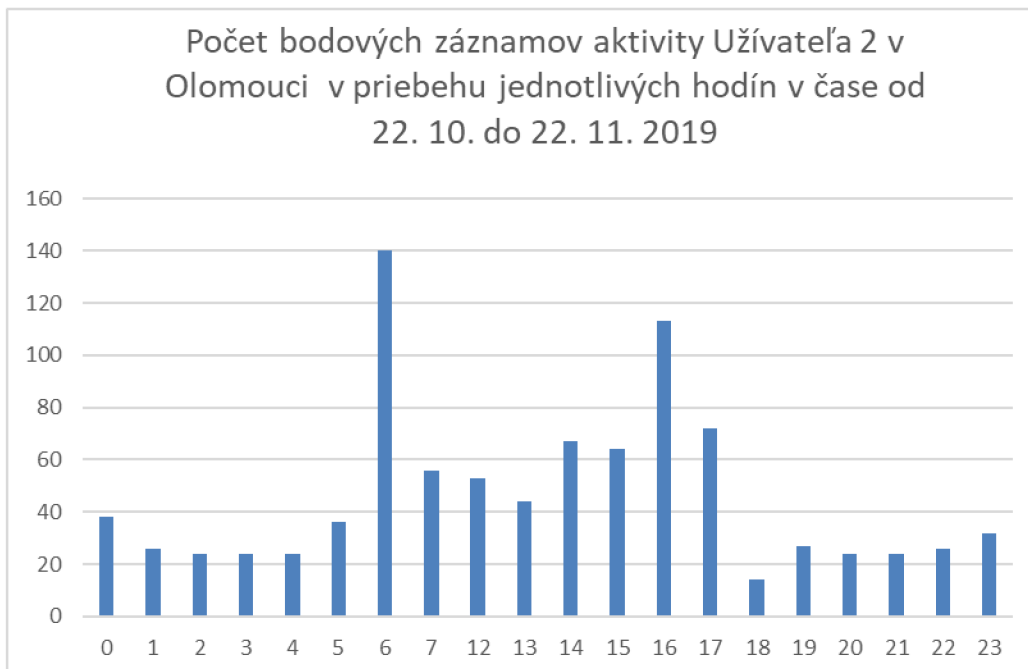
Príloha 3 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 2





Príloha 3 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 2





Príloha 3 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 2





Príloha 3 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 2




Príloha 4 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 3





Príloha 4 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 3



Príloha 4 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 3



Príloha 4 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 3





Príloha 5 – Grafy vytvorené z kontingenčných tabuliek Užívateľa 4

