

Univerzita Palackého v Olomouci

Přírodovědecká fakulta

Katedra geoinformatiky

HODNOCENÍ DISTRIBUCE OBYVATELSTVA Z DAT MOBILNÍHO OPERÁTORA

Bakalářská práce

Vojtěch SVOBODA

Vedoucí práce Mgr. Karel MACKŮ, Ph.D.

Olomouc 2025

Geoinformatika a kartografie

ANOTACE

Tato bakalářská práce se zaměřuje na analýzu prostorových a časových vzorců mobility obyvatelstva v Olomouckém kraji a jeho okolí na základě anonymizovaných dat mobilního operátora Vodafone. Výzkum byl zaměřen na čtyři kategorie přítomnosti osob: rezidenti (dále rozlišení na vyjíždějící a nevyjíždějící), návštěvníci, dojíždějící a celkový počet přítomných osob. Analýza porovnávala jejich pohybová chování ve čtyřech obdobích – v létě a na podzim v roce 2020 a 2022. Tato časová období umožnila porovnat mobilitu v pandemickém a post-pandemickém období. Data byla zpracována pomocí explorační analýzy, prostorové autokorelace (lokální Moranův index) a shlukové analýzy pro identifikaci typologie obcí podle funkčního charakteru. Výsledky ukázaly denní a sezónní vzorce mobility a odhalily prostorové rozdíly mezi jednotlivými kategoriemi osob. Práce zároveň validovala data mobilního operátora Vodafone v kontextu relevance poskytnutých dat prostřednictvím porovnání s daty SLDB 2021 a portálem Kamdojizdime.cz. Navržený metodický rámec může sloužit jako základ pro další analýzy mobility v územním plánování, dopravním modelování či krizovém řízení.

KLÍČOVÁ SLOVA

mobilní lokalizační data; prostorová mobilita; Olomoucký kraj

Počet stran práce: 65

Počet příloh: 39 (z toho 38 vázaných a 1 volná)

ANNOTATION

This bachelor thesis focuses on the analysis of spatial and temporal patterns of population mobility in the Olomouc Region and its surroundings, based on anonymised data from the mobile operator Vodafone. The research focused on four presence categories: residents (further divided into commuters and non-commuters), visitors, inbound commuters, and the total number of present persons. The analysis compared their mobility behaviour across four time periods – in the summer and autumn of 2020 and 2022. These time frames allowed for a comparison of mobility during the pandemic and post-pandemic periods. The data were processed using exploratory data analysis, spatial autocorrelation (local Moran's I), and cluster analysis to identify a typology of municipalities based on their functional character. The results revealed daily and seasonal mobility patterns and uncovered spatial differences between the individual population categories. The thesis also validated the Vodafone mobile data in terms of their relevance by comparing them with data from the 2021 Census and the Kamdojizdime.cz portal. The proposed methodological framework can serve as a basis for further mobility analyses in spatial planning, transport modelling, or crisis management.

KEYWORDS

mobile location data; spatial mobility; Olomouc region

Number of pages: 65

Number of appendices: 39 (38 bound and 1 loose)

Autorským prohlášením se student explicitně přihlašuje k výhradnímu autorství práce a současně vyjadřuje znalost práv UP Olomouc k tomuto dílu. Odevzdáním práce v digitální podobě do evidence STAG student autentizuje toto prohlášení. V případě, že autor v práci navázal na cizí autorské dílo, musí být tato skutečnost v prohlášení výslovně uvedena.

Prohlašuji, že

- bakalářskou/diplomovou práci včetně příloh, jsem vypracoval(a) samostatně a uvedl(a) jsem všechny použité podklady a literaturu.

- jsem si vědom(a), že na moji bakalářskou/diplomovou práci se plně vztahuje zákon č.121/2000 Sb. - autorský zákon, zejména § 35 – využití díla v rámci občanských a náboženských obřadů, v rámci školních představení a využití díla školního a § 60 – školní dílo,

- beru na vědomí, že Univerzita Palackého v Olomouci (dále UP Olomouc) má právo nevýdělečně, ke své vnitřní potřebě, bakalářskou/diplomovou práci užívat (§ 35 odst. 3),

- souhlasím, že údaje o mé bakalářské/diplomové práci budou zveřejněny ve Studijním informačním systému UP,

- v případě zájmu UP Olomouc uzavřu licenční smlouvu s oprávněním užít výsledky a výstupy mé bakalářské/diplomové práce v rozsahu § 12 odst. 4 autorského zákona,

- použít výsledky a výstupy mé bakalářské/diplomové práce nebo poskytnout licenci k jejímu využití mohu jen se souhlasem UP Olomouc, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly UP Olomouc na vytvoření díla vynaloženy (až do jejich skutečné výše).

Děkuji vedoucímu práce Mgr. Karel Macků Ph.D. za podněty a připomínky při vypracování práce. Dále děkuji konzultantu Mgr. Radek Barvíř, Ph.D. za podněty a připomínky k mapovým výstupům.

UNIVERZITA PALACKÉHO V OLOMOUCI

Přírodovědecká fakulta

Akademický rok: 2023/2024

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Vojtěch SVOBODA**
Osobní číslo: **R22611**
Studijní program: **B0532A330011 Geoinformatika a kartografie**
Téma práce: **Hodnocení distribuce obyvatelstva z dat mobilního operátora**
Zadávající katedra: **Katedra geoinformatiky**

Zásady pro vypracování

Cílem bakalářské práce je porovnat změny stavu obyvatelstva vybraných katastrálních území Olomouckého kraje pomocí dat o poloze osob získaných od mobilního operátora Vodafone. Student navrhne vhodné metody zpracování, analýzy a vizualizace dostupných dat, které umožní vhodně prezentovat variace ve změnách jednotlivých kategorií osob (residenti, návštěvníci, nevíždějící a vyjíždějící za prací). Dynamika změn bude vyjádřena díky hodinovým a denním variacím, dále budou porovnávána zkoumána rozdílnost vlivem různých časových období (období léto/ podzim, v letech 2020 a 2022). Výsledná zjištění budou vhodně prezentována v tabelární a grafické podobě, mimo jiné ve webovém prostředí formou interaktivní mapy.

Text práce student zpracuje v souladu se závaznou šablonou pro kvalifikační práce KGI. O diplomové práci student vytvoří webovou stránku a poster. Celou práci (text, přílohy, výstupy, zdrojová a vytvořená data, poster a web) odevzdá student v digitální podobě na datové úložiště katedry. Do evidence STAG student odevzdá úplný text práce s přílohami, které určí vedoucí práce. Fyzicky student odevzdá pouze přílohy určené vedoucím práce.

Rozsah pracovní zprávy: **max. 50 stran**
Rozsah grafických prací: **dle potřeby**
Forma zpracování bakalářské práce: **elektronická**

Seznam doporučené literatury:

- Batty, M. (2013). Big data, smart cities and city planning. *Dialogues in Human Geography*, 3(3), 274–279. doi:10.1177/2043820613513390 PMID:29472982
- Kahrik, A., Novák, J., Temelová, J., Kadarik, K., & Tammaru, T. (2015). Patterns and Drivers of Inner City Social Differentiation in Prague and Tallinn. *Geografie (Utrecht)*, 120(2), 275–295. doi:10.37040/geografie2015120020275
- Louail, T., Lenormand, M., Cantu Ros, O. et al. From mobile phone data to the spatial structure of cities. *Sci Rep* 4, 5276 (2014). <https://doi.org/10.1038/srep05276>
- Novák, J., & Temelová, J. (2012). Everyday Life and Spatial Mobility of Young People in Prague: A Pilot Study Using Mobile Phone Location Data. *Sociologický časopis-Czech Sociological Review*, 48(5), 911–938. doi:10.13060/00380288.2012.48.5.05
- Sevtsuk, A., & Ratti, C. (2010). Does Urban mobility have a daily routine? Learning from the aggregate data of mobile networks. *Journal of Urban Technology*, 17(1), 41–6041–60.
- Trasarti, R., Olteanu-Raimond, A., Nanni, M., Couronné, T., Furletti, B., Giannotti, F., Smoreda, Z., & Ziemlicki, C. (2015). Discovering urban and country dynamics from mobile phone data with spatial correlation patterns. *Telecommunications Policy*, 39(3–4), 347–362. <https://doi.org/10.1016/j.telpol.2013.12.002>

Vedoucí bakalářské práce: **Mgr. Karel Macků, Ph.D.**
Katedra geoinformatiky

Datum zadání bakalářské práce: **3. května 2024**
Termín odevzdání bakalářské práce: **7. května 2025**

L.S.

doc. RNDr. Martin Kubala, Ph.D.
děkan



prof. RNDr. Vilém Pechanec, Ph.D.
vedoucí katedry

V Olomouci dne 16. září 2024

OBSAH

| | |
|---|-----------|
| SEZNAM POUŽITÝCH ZKRATEK | 10 |
| ÚVOD | 11 |
| 1 CÍLE PRÁCE | 12 |
| 2 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY | 13 |
| 2.1 Mobilní polohová data a lokalizační technologie | 13 |
| 2.1.1 Význam a historie mobilních polohových dat..... | 13 |
| 2.1.2 Lokalizační technologie a zdroje dat | 13 |
| 2.2 Aplikační příklady využití mobilních dat | 14 |
| 2.2.1 Prostorová struktura a městské prostředí | 14 |
| 2.2.2 Krizové řízení a modelování šíření nemocí | 15 |
| 2.2.3 Socioekonomické a sezónní aspekty mobility..... | 16 |
| 2.3 Analytické přístupy pro vyhodnocení mobility | 16 |
| 2.3.1 Prostorové analýzy..... | 16 |
| 2.3.2 Časoprostorové modely a trendy | 17 |
| 2.3.3 Shluková analýza a typologie | 18 |
| 2.4 Vizualizace dat o mobilitě | 19 |
| 2.4.1 Základní kartografické metody vizualizace dat..... | 19 |
| 2.4.2 Heat-mapy a animace..... | 20 |
| 2.4.3 Interaktivní dashboardy | 21 |
| 3 METODY A POSTUP ZPRACOVÁNÍ | 23 |
| 3.1 Použité metody | 23 |
| 3.1.1 Explorační analýza dat (EDA)..... | 23 |
| 3.1.2 Prostorová autokorelace | 24 |
| 3.1.3 Shluková analýza (multivariate clustering) | 25 |
| 3.1.4 Typologie..... | 25 |
| 3.2 Použitá data..... | 26 |
| 3.3 Použité programy | 27 |
| 4 EXPLORAČNÍ ANALÝZA | 29 |
| 4.1 Porovnání denního režimu různých kategorií osob | 29 |
| 4.2 Identifikace vzorů v distribuci kategorií osob..... | 31 |
| 4.3 Identifikace obcí s největšími změnami v mobilitě osob..... | 34 |
| 4.4 Analýza vnitřní struktury populace obcí | 36 |
| 4.5 Animace změn přítomnosti rezidentů a návštěvníků..... | 40 |
| 4.6 Ukazatele mobility..... | 41 |
| 4.6.1 Mobilita rezidentů a relativní balance dojížděky | 41 |
| 5 ANALÝZA ZMĚN V DOJÍŽDĚNÍ | 44 |
| 6 SHLUKOVÁ ANALÝZA A TVORBA TYPOLOGIE | 48 |
| 6.1 Testování různých počtů shluků a výběr optimální varianty | 48 |
| 6.2 Interpretace typologie při K=5..... | 49 |
| 6.3 Typologie obcí dle letní a podzimní sezóny (2022) | 54 |
| 7 VALIDACE DAT | 57 |

| | |
|---|-----------|
| 7.1 Porovnání dat MPD vs SLDB 2021 | 57 |
| 7.2 Porovnání dat Vodafone se souhrnnými daty mobilních operátorů (Kamdojizdime.cz) 57 | |
| 8 VÝSLEDKY | 61 |
| 8.1 Explorační analýza prostorové a časové mobility | 61 |
| 8.2 Zkoumání změn dojíždění pomocí prostorových analýz..... | 61 |
| 8.3 Typologie obcí na základě shlukové analýzy | 62 |
| 8.4 Validace dat a interpretace mobility..... | 62 |
| 9 DISKUZE | 63 |
| 10 ZÁVĚR | 65 |
| POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE | |
| PŘÍLOHY | |

SEZNAM POUŽITÝCH ZKRATEK

| Zkratka | Význam |
|----------------|---|
| ArcČR | Digitální geografická databáze České republiky |
| BTS | Base Transceiver Station |
| COVID-19 | Coronavirus Disease 2019 |
| ČSÚ | Český statistický úřad |
| DBSCAN | Density-Based Spatial Clustering of Applications with Noise |
| EDA | Exploratory Data Analysis |
| GDB | Geodatabase |
| GIS | Geographic Information System |
| GMM | Gaussian Mixture Model |
| GPS | Global Positioning System |
| JHU | John Hopkins University |
| LISA | Local Indicators of Spatial Association |
| LiDAR | Light Detection and Ranging |
| MPD | Mobile positioning data |
| OD | Origin-Destination |
| RSS | Received Signal Strength |
| SHP | Shapefile |
| SIM | Subscriber Identity Module |
| SLDB | Sčítání lidu, domů a bytů |
| TDOA | Time Difference of Arrival |
| UP | Univerzita Palackého |
| VPN | Virtual Private Network |
| Wi-Fi | Wireless Fidelity |

ÚVOD

Mobilita obyvatelstva představuje klíčový aspekt porozumění fungování společnosti, regionálních vztahů a každodenního života. S rostoucí dostupností nových datových zdrojů, jako jsou anonymizovaná data od mobilních operátorů, se otevírají nové možnosti analýzy prostorových a časových vzorců pohybu osob. Tyto datové sady umožňují sledovat dynamiku populace s vysokým časovým i prostorovým rozlišením a přispívají tak k hlubšímu porozumění demografickým, ekonomickým a sociálním procesům.

Tato bakalářská práce se zaměřuje na prostorovou a časovou analýzu obyvatel na území Olomouckého kraje a jeho blízkého okolí, a to na základě dat poskytnutých mobilním operátorem Vodafone. Práce se opírá o kombinaci explorační analýzy a pokročilejších prostorových a statistických metod, které umožňují nejen podrobně popsat časoprostorové chování obyvatel, ale také odhalit regionální odlišnosti a identifikovat klíčové změny v dynamice populace. Získaná zjištění mohou být užitečná pro územní plánování, rozvoj infrastruktury, krizové řízení či posuzování atraktivity obcí.

Motivací pro výběr tématu byla nejen rostoucí důležitost analýzy mobility v současné společnosti, ale také snaha ověřit praktické využití moderních datových zdrojů v oblasti regionální analýzy. Práce navazuje na předchozí výzkumy v oblasti geoinformatiky a snaží se rozšířit metodické nástroje o nové přístupy založené na analýze mobilních dat.

1 CÍLE PRÁCE

Cílem bakalářské práce je analyzovat prostorové a časové změny rozložení obyvatelstva ve vybraných obcích a katastrálních územích Olomouckého kraje pomocí mobilních lokalizačních dat operátora Vodafone. Zaměřit se na sledování různých kategorií osob (rezidenti, včetně vyjíždějících a nevyjíždějících, dojíždějící, návštěvníci a celkový počet přítomných osob), a porovnat jejich chování mezi letním a podzimním obdobím v letech 2020 a 2022, zároveň zahrnout i vliv pandemie Covid-19 v kontextu změn mobility obyvatel.

Zachytit denní i hodinovou dynamiku pohybu osob a prostorové rozdíly mezi obcemi. Výsledky vhodně vizualizovat pomocí grafických, tabelárních a kartografických výstupů, včetně publikace v podobě interaktivní webové mapy. Na základě rozpoznaných vzorců mobility a všemi zjištěními navrhnout typologii obcí a ověřit vypovídací schopnost dat porovnáním s referenčními údaji ze SLDB 2021 a sadou FD3 z portálu Kamdojizdime.cz.

Zvláštní důraz je kladen na vytvoření přehledného a opakovatelného metodologického postupu, který ukáže, jak systematicky pracovat s mobilními lokalizačními daty pro účely prostorové analýzy a výzkumu populační mobility.

2 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

2.1 Mobilní polohová data a lokalizační technologie

2.1.1 Význam a historie mobilních polohových dat

V dnešní době rychlých změn a inovací je život kolem nás čím dál víc hektický, proto je klíčové sledovat, jak a kam se lidé pohybují. Určování polohy a analýzy mobility dnes hrají zásadní roli v porozumění dynamiky lidského pohybu. Moderní způsoby umožňují nejen přesně určit polohu, ale také analyzovat odvozenou mobilitu. Odvozenou mobilitu lze definovat jako koncept popisující pohyb jednotlivců či skupin v prostoru a čase na základě nepřímých datových zdrojů.

Data mobilních operátorů bývají zpravidla anonymizována a agregována pro zajištění ochrany soukromí uživatelů. V posledních letech tato data úplně změnila pohled na to, jak můžeme analyzovat vzorce chování obyvatel. Na rozdíl od tradičních metod, jako jsou sčítání lidu nebo dotazníková šetření, „Data mobilních telefonů mají shromažďování v reálném čase, široké pokrytí a výhody vysokého rozlišení a lze je tak použít k charakterizaci lidských aktivit a distribuce populace v jemných časoprostorových měřících“ (Wei et al., 2023). Díky těmto nástrojům lze sledovat nejen každodenní rutiny lidí, ale také sezónní výkyvy a krizové situace, které běžné metody jednoduše nezvládají. Jednou z největších výhod mobilních dat je možnost rozlišovat mezi různými skupinami obyvatel. Rezidenti, tedy lidé, kteří v oblasti trvale žijí, mají zcela jiné vzorce chování než například návštěvníci, kteří se v oblasti objeví pouze na krátkou dobu například kvůli turistice. Dojíždějící, kteří pravidelně cestují za prací nebo školou zase tvoří úplně jiný vzorec. Schopnost rozlišovat různé skupiny je nesmírně cenná pro města a regiony, protože jim pomáhá lépe plánovat dopravu, služby a celkovou infrastrukturu tak, aby odpovídaly skutečným potřebám obyvatel.

Historicky se analýza mobility spoléhala na statické zdroje dat, jako je výše zmíněné sčítání lidu a dotazníková šetření. Statické zdroje však neumožňovaly sledovat změny v reálném čase. Dle Pospíšilové a Nováka (2016), „První projekty a studie, které se zabývají daty mobilních telefonů, jsou také poměrně nedávné, datované pouze do 90. let 20. století. Tyto rané studie byly spíše izolované a teprve po roce 2005 se staly údaje o poloze mobilních telefonů rozšířenější“. První pokusy v 90. letech znamenaly zásadní posun v možnosti analyzovat prostorovou mobilitu s vyšší přesností a s pravidelně aktualizovanými daty. Samozřejmě s příchodem GPS a rozvojem mobilních sítí postupně rostla jejich přesnost a dostupnost. Dnes se mobilní data běžně využívají ve všech napříč všemi různými sférami.

2.1.2 Lokalizační technologie a zdroje dat

Určování polohy hraje dnes zásadní roli v mnoha oblastech lidské činnosti, od běžného života až po vědecký výzkum a aplikace v praxi. Přesné stanovení polohy je nezbytné pro širokou škálu oborů včetně geoinformatiky. V dnešní době se poloha určuje nejen tradičními geodetickými metodami, ale i pomocí moderních technologií, jako jsou družicové navigační systémy, fotogrammetrie, laserové skenování či analýza signálu mobilních operátorů. Metody určování polohy lze rozdělit na přímé a nepřímé.

Přímé metody určování polohy spočívají v tom, že poloha objektu je stanovena přímo měřením jeho souřadnic, například zeměpisné šířky, délky a nadmořské výšky. Mezi přímé

metody určování polohy lze řadit GNSS (Globální navigační satelitní systémy), geodetické metody, fotogrammetrii či dálkový průzkum země a laserové skenování (LiDAR).

Nepřímé metody určování polohy naopak spočívají v tom, že poloha objektu je stanovena na základě jiných údajů, než jsou souřadnice, například z odvozených hodnot. Mezi nepřímé metody určování polohy lze řadit interpolaci a extrapolaci, triangulaci a trilateraci, nebo analýzy signálů a síťových údajů. Pro účely této práce budou stručně popsány pouze vybrané metody.

První ze zmíněných metod přímého určování polohy je metoda s pomocí GPS. Výhodou GPS je, že poskytuje vysokou přesnost. Dostupnost signálů však vyžaduje přímou viditelnost satelitů, kterou nelze garantovat všude, zvláště v husté zástavbě či uvnitř budov (Bartolík, 2024). Kromě GPS lze k lokalizaci zařízení využít také Wi-Fi sítě, které jsou zvláště užitečné v prostředích, kde je signál GPS omezený, například uvnitř budov. Zatímco GPS poskytuje vysokou přesnost v otevřených prostorech, jeho spolehlivost klesá v interiérech, kde mohou být pro určování polohy efektivnější Wi-Fi sítě (Kotva, 2017). Obě z výše popsaných metod tedy nabízí něco jiného a hodí se pro jiné účely a podmínky.

Jeden z nepřímých datových zdrojů mohou být data mobilních operátorů. Zmíněná data jsou získávána pomocí záznamů z interakcí mobilních zařízení se základnovými stanicemi. Základnové stanice (BTS) jsou důležitým prvkem mobilní sítě, který umožňuje komunikaci mezi mobilními zařízeními a jádrem sítě. BTS slouží k lokalizaci zařízení pomocí rádiového signálu a triangulace, což umožňuje sledování pohybu (Novák, 2010). Nejjednodušší metodou lokalizace v mobilních sítích je Cell Global Identity, kde je poloha zařízení odhadována na základě identifikátoru buňky, k níž je zařízení aktuálně připojeno. Uvedená metoda však není dostatečně přesná. Pro přesnější lokalizaci se používá metoda triangulace. Zmíněná metoda využívá k určení přibližné polohy zařízení měření signálu ze tří nebo více základových stanic (BTS). Popsaný princip funguje na základě měření časového zpoždění (Time Difference of Arrival, TDOA), nebo síly signálu (Received Signal Strength, RSS), které mobilní telefon přijímá z různých BTS v jeho okolí. Čím více BTS mobilní zařízení zachytí, tím přesnější je výsledná lokalizace. Metoda se využívá nejčastěji v městských oblastech, kde je hustota BTS velmi vysoká, což umožňuje dosažení přesnosti řádově v desítkách metrů.

Alternativou k datům mobilního operátora, zároveň rostoucím fenoménem v této době je využití personalizovaných dat. Například data z Google Location mohou přinést ještě detailnější pohled na prostorové vzorce obyvatel. Burian, et. al. (2021) se ve své studii zaměřili na analýzu těchto dat v období pandemie COVID-19 a ukázali, že tradiční metody se těmto datům nemohou rovnat. Z jejich závěrů vyplývá, že tato data dobře zachycují změny v cestovních návycích a mohou být užitečná při hodnocení efektivity různých opatření.

Zatímco existuje řada metod určování polohy, pro tuto práci jsou klíčová agregovaná anonymizovaná data mobilního operátora, která vycházejí z interakcí zařízení se základnovými stanicemi. Jejich výhodou je vysoké pokrytí, možnost rozlišení různých typů přítomnosti osob a využití v různých časových obdobích, což je pro výzkum dynamiky obyvatelstva zásadní.

2.2 Aplikační příklady využití mobilních dat

2.2.1 Prostorová struktura a městské prostředí

Mobilní data se stala pro společnost nenahraditelným zdrojem informací v různých oblastech výzkumu. Práce autorů Vanhoof et al. (2018) se věnovala analýze přesnosti

metod detekce domovských lokalit z dat od mobilního operátora pomocí různých algoritmů. Autoři ve své studii prokázali, že „různé algoritmy detekce domovské lokality mohou vést k výrazně odlišným výsledkům a jejich přesnost závisí na použité metodě a délce období pozorování" (Vanhoof et al., 2018). Uvedené výsledky naznačují, že mobilní data mají potenciál pro doplnění tradičních statistických metod, jako je sčítání lidu, je však nutná validace pomocí referenčních údajů. Celkově lze shrnout, že mobilní data jsou cenným doplňkem demografických analýz, ale mají svá specifická omezení.

Pro analýzu prostorové struktury měst a studium dynamiky lidského chování jsou mobilní data velmi cenná. Dle autorů Louail et al. (2014) "Nedávným, velmi důležitým zdrojem dat jsou data jednotlivých mobilních telefonů. Tato data umožnila studovat individuální vzorce mobility s vysokou prostorovou a časovou přesností". Citovaná studie analyzovala data z mobilních telefonů zaznamenaná během 55 dnů ve 31 španělských metropolích. Cílem výzkumu bylo pochopit, jak se mění průměrná vzdálenost mezi jednotlivci v průběhu dne, a díky těmto zjištěním identifikovat nejvíce frekventovaná místa tzv. „hotspoty“. Práce dokázala identifikovat jednotlivé typy městských struktur a řadu hotspotů. Výsledky ukázaly, že městské hotspoty mají stabilní hierarchii v čase, ale jejich prostorová distribuce se může lišit v závislosti na velikosti města a jeho struktuře. Jak shrnují Louail et al. (2014), mobilní data nám umožňují odhalit základní prostorovou organizaci měst a lépe pochopit, jak lidé využívají městský prostor v průběhu dne. Jejich studie dále ukázala, že větší města efektivněji využívají svůj prostor než města menší.

Studie autorů Trasarti et al. (2015) ukazuje, jak můžeme pomocí kombinace GPS trajektorií a kontextových informací identifikovat opakující se vzorce v pohybu obyvatel. Tyto vzorce lze využít například pro predikci budoucí mobility. Autoři zdůrazňují, že analýza velkých prostorově-časových dat poskytuje nový náhled na dynamiku městské mobility a může pomoci při plánování dopravní infrastruktury. Výsledky studie rovněž dokládají, že lze mobilní data využít pro zefektivnění řízení dopravy a veřejných služeb. Pro pochopení každodenních aktivit obyvatel využili Novák a Temelová (2012) mobilní data v kombinaci s dotazníkovým šetřením. Výsledky jejich studie odhalily opakující se vzorce v denní mobilitě mladých lidí a dokázaly identifikovat klíčová místa jejich aktivit. "Hloubková sonda do komplexní podoby každodenního života odhalila některé strategie a denní praktiky, které jednotlivci a domácnosti využívají k překonávání vzdálenosti mezi bydlištěm a místy lokalizace pracovní a obslužné funkce a jejichž podoba závisí především na stadiu životního cyklu, socio-ekonomickém postavení a věku", dodávají Novák a Temelová (2012).

2.2.2 Krizové řízení a modelování šíření nemoci

Díky své jedinečné vlastnosti přesného mapování lidské mobility mobilní data získala efektivní využití rovněž při modelování šíření infekčních onemocnění. Studie autorů Tizzoni et al. (2014) využívala mobilní data jako náhradu za tradiční údaje o dojíždění při predikci šíření epidemií. Byly porovnávány tři zdroje dat o mobilitě: údaje ze sčítání lidu, mobilní data a matematické (radiační) modely sloužící pro předpovědi dojíždění na základě vzdálenosti a populační hustoty. Výsledky ukazují, že mobilní data dobře odpovídají skutečným vzorcům dojíždění, protože pokrývají velkou škálu reálných dopravních toků. Na druhou stranu zmíněná data oproti tradičním datům nadhodnocují intenzitu dopravy, což vedlo k rychlejšímu šíření simulovaných epidemií. I přes tyto nedostatky data správně předpověděla pořadí infikování různých lokalit, což je důležité zjištění pro vytváření různých opatření a organizaci krizového řízení během epidemií.

Mobilní data umožňují sledovat šíření nemocí v reálném čase a mohou být užitečná v regionech, kde chybí podrobné statistiky o mobilitě obyvatel. V rámci eliminace zkreslení výsledků je však nutné zajistit správnou kalibraci dat.

Mobilní data hrála také významnou roli v pandemii COVID-19. Studie autorů Oliver et al. (2020) analyzuje, jak lze tato data využít pro podporu veřejného zdraví během různých fází pandemie. Autoři uvádějí, že "mobilní telefonní data, pokud jsou správně a pečlivě využívána, představují kritický soubor nástrojů pro podporu opatření veřejného zdraví ve všech fázích pandemie COVID-19", (Oliver et al., 2020). Využití mobilních dat zahrnuje široké spektrum uplatnění: od monitorování šíření viru až po hodnocení účinnosti restrikcí a plánování očkovacích kampaní. V uvedené studii byly využity metody sledování změn pohybu obyvatel před a po zavedení různých opatření v různých zemích. Byla porovnávána data o mobilitě s počtem nakažených, hospitalizací a úmrtí. Dále byl modelován dopad konkrétních opatření a byla hodnocena efektivita lockdownů a omezování cestování. Tato studie jasně dokládá důležitost mobilních dat při epidemiích jako je COVID-19. Závěry citované studie dokládají, že v zemích, kde byla mobilita výrazně omezena (např. Itálie, Španělsko), se šíření viru zpomalilo rychleji než v regionech s menšími restrikcemi.

2.2.3 Socioekonomické a sezónní aspekty mobility

Mobilní data mají obrovský potenciál při analýze v souvislosti se socioekonomickými faktory. Z ryze socioekonomické analýzy, bez využití mobilních polohových dat lze zmínit autory Káhrík et al. (2015), kteří analyzují socioekonomickou diferenciaci vnitřních měst v Praze a Tallinnu a ukazují, že socioekonomický status domácností ovlivňuje preference pro bydlení v městském centru. Výsledky dále naznačují, že skupiny s vyššími příjmy mají větší tendenci k určitému typu městského prostředí, zatímco skupiny s nižšími příjmy zůstávají v méně atraktivních oblastech města. Tyto informace mohou nepřímo ovlivnit vzorce mobility ve městech. Na denní mobilitu v městském prostředí již dříve upozornily práce jako Trasarti et al. (2015) či Novák a Temelová (2012) (viz kapitola 2.2.1), které poukazují na význam opakujících se pohybových vzorců a režimu obyvatel.

Dalším významným aspektem, jsou sezónní změny mobility. Autoři Ahas et al. (2007) ukazují, že sezónní vzorce mají zásadní vliv na prostorové rozložení turistů, což ovlivňuje infrastrukturu a služby v turisticky exponovaných oblastech. Analýza mobilních dat poskytuje přehled o dynamice návštěvnosti. V Česku lze mluvit například o Jeseníku, kde jsou výrazné výkyvy návštěvníků mezi různými obdobími a dále pak výkyvy v kontextu využívání služeb. V oblastech jako jsou Krkonoše se pravděpodobně změny mobility projevují především během zimní sezony, kdy oblast očekává větší množství návštěvníků spojené s nárůstem návštěv rekreačních zařízení. Díky těmto poznatkům lze lépe přizpůsobit veřejnou dopravu a služby aktuální poptávce. Zmíněná tvrzení dokládají i autoři Trasarti et al. (2015), kteří zmiňují, že analýzy mobilních dat mohou odhalit zásadní vzorce chování v různých oblastech a obdobích.

2.3 Analytické přístupy pro vyhodnocení mobility

2.3.1 Prostorové analýzy

Prostorové analýzy se zaměřují na identifikaci prostorových vzorců a koncentrací pohybu obyvatel. Jednou z nejčastěji používaných metod je metoda jádrových odhadů (Kernel Density Estimation), která slouží k odhadu pravděpodobnostní hustoty jevů v prostoru. V kontextu mobility tato metoda pomáhá identifikovat oblasti s vysokou koncentrací osob nebo pohybu – tzv. „hotspoty“. Výhodou jádrových odhadů je snadná

vizualizace a interpretace prostorové distribuce. Nevýhodou může být nutnost volby vhodného nastavení parametrů, které výrazně ovlivňuje výsledky. Metoda je vhodná pro základní průzkum prostorové koncentrace, nikoliv však pro odhalení hlubších vzorců a vztahů.

Louail et al. (2014) využili ve své studii jádrové odhady k identifikaci oblastí s vysokou koncentrací mobility ve Španělských městech (viz Obrázek 1), včetně Barcelony, nebo Madridu. Studie ukázala rozdíly mezi městskými částmi v koncentraci obyvatel během různých časových období. Některé městské části si udržují konzistentně vysokou koncentraci obyvatel během celého dne, v jiných lze pozorovat výkyvy. Například v Madridu se ukázala vysoká koncentrace obyvatel během pracovního dne v obchodních čtvrtích, zatímco večer se mobilita přesouvala do rezidenčních oblastí.

Jádrové odhady lze kombinovat i s prostorovou autokorelací. Tento přístup využili Wei et al. (2023) při studiu prostorového rozložení populace na základě mobilních dat. Prvním krokem bylo využití jádrových odhadů, což umožnilo vizualizovat oblasti s vyšší a nižší koncentrací obyvatel. Autoři došli k zjištění, že populační hustota nevykazuje rovnoměrné rozložení, ale naopak vykazuje jasné časoprostorové vzory závislé na čase a typu městské zástavby. Pro hlubší vhled autoři dále aplikovali analýzu prostorové autokorelace. Uvedená metoda umožňuje odhalit statisticky významné shluky vysokých a nízkých hodnot. Pro analýzy byly využity různé algoritmy, například lokální Moranův index pro detekci hotspotů. Výsledky dokládají, že centrální městské části vykazují trvale vysokou hustotu obyvatel během dne, zatímco okrajové oblasti vykazují větší rozdíly mezi dnem a nocí. Následně provedli autoři diferenciální analýzu populační aktivity dle využití území, díky které lépe porozuměli rozdílům v distribuci obyvatelstva. Využití kombinace s dalšími metodami je významné pro odhalení skrytých vzorů v distribuci populace.

2.3.2 Časoprostorové modely a trendy

Časoprostorové analýzy kombinují prostorové a časové aspekty pohybu, což umožňuje sledovat změny v mobilitě obyvatel v čase a prostoru zároveň. Tyto metody se využívají například ke sledování denních rytmů pohybu, detekci špiček či poklesů mobility nebo k modelování šíření jevů závislých na pohybu obyvatel.

Výhodou těchto metod je schopnost zachytit dynamiku jevů a zohlednit jejich vývoj v čase. Nevýhodou může být vysoká datová a výpočetní náročnost.

Oliver et al. (2020) použili časoprostorovou analýzu mobilních dat k modelování změn mobility během pandemie COVID-19 ve více zemích, včetně Španělska, Itálie a Francie. Výsledky ukázaly výrazný pokles mobility během prvního měsíce lockdownu v Madridu, zatímco ve venkovských regionech byl zaznamenán méně výrazný pokles. Trasarti et al. (2015) analyzovali časoprostorové vzory mobility ve Francii, zejména v Paříži, kde sledovali změny v pohybu mezi pracovními a rezidenčními oblastmi během dne. Výsledky ukázaly, že v Paříži došlo mezi 7:00 a 9:00 ke skokovému nárůstu mobility ve směru z předměstí do centra města, přičemž významnou roli hrály hlavní dopravní uzly jako například letiště Charles de Gaulle a vlakové stanice. Data ukázala konkrétní časy zatížení jak veřejné, tak automobilové dopravy.

Tizzoni et al. (2014) ve své studii modelovali epidemiologické procesy na základě časoprostorových vzorců mobility. Cílem bylo analyzovat prostorové vzorce pohybu populace a jejich vliv na šíření infekčních nemocí. Autoři porovnali různé přístupy k modelování mobility včetně gravitačního modelu a radiačního modelu. Gravitační model předpokládá, že mobilita mezi dvěma místy závisí na velikosti populace těchto míst a vzdálenosti mezi nimi. Radiační model lze chápat jako alternativu, která nevyžaduje

kalibraci pomocí empirických dat. Nakonec se radiační model ukázal jako přesnější pro predikci šíření infekčních nemocí, jelikož lépe zachycuje skutečné pohybové vzorce. Propojení epidemiologických modelů s mobilními daty umožnilo následnou analýzu šíření nemocí na základě reálných pohybových vzorců obyvatelstva.

Sevtsuk a Ratti (2010) využili kombinaci časoprostorového modelování a Fourierových transformací. Zjišťovali, zda lze identifikovat z mobilních dat opakující se vzory mobility. Fourierova analýza reprezentuje matematickou metodu umožňující extrakci dominantní frekvence z časových řad. V rámci uvedené studie bylo zjištěno, že denní vzorce mobility vykazují pravidelný rytmus s výraznými špičkami během ranního a odpoledního doježdění. Fourierova analýza umožnila najít klíčové frekvence v datech a odhalit dominantní vzorce mobility ve městě.

2.3.3 Shluková analýza a typologie

Shluková analýza slouží k seskupování objektů na základě podobnosti určitých charakteristik, v tomto případě vzorců mobility. Tato metoda je užitečná zejména při tvorbě typologií městských oblastí a zkoumání změn v jejich struktuře mezi různými obdobími.

Mezi výhody patří schopnost odhalit skryté struktury v datech a rozpoznat homogenní oblasti s podobným chováním. Nevýhodou je opět nutnost správného nastavení vstupních parametrů (např. počet shluků) a někdy obtížná interpretace výsledků, zejména při velkém množství parametrů.

Studie Nováka a Temelové (2012) demonstrovala využití této metody při analýze každodenní prostorové mobility mladých obyvatel města Prahy. Jak již bylo zmíněno výše, autoři identifikovali různé typy denní mobility. Zjistili, že vzorce pohybu obyvatel jsou ovlivněny prací, bydlištěm a volnočasovými aktivitami. Díky těmto analýzám byli schopni identifikovat oblasti, které trpí například přetížením dopravy, nebo naopak oblasti s nízkou návštěvností, kde je nutné podpořit místní ekonomiku. Shlukové analýzy, jež autoři ve své studii využili se ukázaly být velmi účinnými nástroji rovněž při vytváření typologií městských částí. Autoři Wei et al. (2023) ve své studii využili shlukovou analýzu k rozlišení různých typů městských částí na základě prostorové distribuce populace. Jejich výsledky dokládají, že určité oblasti mají vysokou koncentraci obyvatel během pracovních hodin, zatímco jiné oblasti vykazují odlišné vzorce, spojené například s volnočasovou aktivitou. Autoři uvádějí: „Naše studie ukázala, že obecně, bez ohledu na to, zda šlo o denní nebo noční dobu, hustota městské populace vykazovala výrazný útlumový vzorec mezi centrem města a jeho periferií“, (Wei et al., 2023).

Práce autorů Trasarti et al. (2015) se zabývala analýzou urbanistické dynamiky pomocí shlukové analýzy. Shluková analýza zde byla využita k seskupování geografických oblastí s podobnými vzorci pohybu obyvatel během dne. Pro zjištění časových trendů pohybu mezi jednotlivými oblastmi byla využita hierarchická shluková analýza. Analýza byla rozšířena o metodu C-patterns, jež umožnila zjistit, jak změny hustoty populace v jedné oblasti ovlivňují hustotu v jiných regionech.

Autoři Vanhoof et al. (2018) se ve své studii zabývali identifikací významných míst pomocí shlukové analýzy. K seskupení míst s vysokou frekvencí pobytu jednotlivých uživatelů byla využita metoda K-means. Po identifikaci shluků byla využita logistická regrese, jež přiřazovala význam těmto místům na základě časových a prostorových vzorů přítomnosti uživatelů. Výsledky přispěly k vylepšení modelování mobility obyvatel.

Použité metody zmíněné v kapitole 2.3, jejich krátký popis, příklady aplikací a autor dané práce je stručně shrnuto v Tabulce 1.

Tabulka 1 – přehledová tabulka metod, příkladů aplikace a autorů prací

| Použitá metoda | Popis metody | Příklady aplikace | Autor práce |
|-------------------------|---|---|--|
| jádrové odhady | vizualizace prostorové hustoty jevu, detekce oblastí s vysokou koncentrací (hotspoty) | plánování dopravní infrastruktury ve velkých metropolích, jako je Paříž či Londýn | Louail et al. (2014) |
| prostorová autokorelace | statistické zhodnocení prostorových shluků a identifikace odlehlých hodnot | identifikace prostorově významných koncentrací různých typů obyvatel v různých obdobích | Wei et al. (2023) |
| shluková analýza | seskupování území na základě podobnosti v distribuci či struktury obyvatel. | typologie obcí, optimalizace veřejných služeb v Praze | Novák a Temelová (2012), Vanhoof et al. (2018), Trasarti et al. (2015) |
| časoprostorové modely | kombinace prostorových a časových dat | identifikace dopravních špiček, lepší plánování veřejné dopravy | Trasarti et al. (2015), Tizzoni et al. (2014), Sevtsuk a Ratti (2010) |

Možnosti využití vybraných metod ve vlastní práci

V kontextu této práce se dle literární rešerše a struktury poskytnutých mobilních polohových dat od Vodafone s definovanými kategoriemi osob (rezidenti, z toho vyjíždějící a nevyjíždějící, návštěvníci a dojíždějící za prací a do škol) se jeví následující analytické metody jako potenciálně využitelné při snaze naplnění cílů této práce.

- **prostorová autokorelace (lokální Moranův index):** metoda vhodná pro identifikaci prostorových shluků a odlehlých hodnot, zejména při hodnocení různých kategorií obyvatel a jejich koncentrací v různých časových obdobích. Využití této metody by mohlo pomoci identifikovat významné shluky a odchylky různých kategorií osob a tyto poznatky následně využít pro další hlubší analýzy
- **shluková analýza:** umožní vytvořit typologii obcí na základě podobnosti pohybových vzorců, srovnat různá časová období a zobrazit celkovou dynamiku a složení obyvatel v jednotlivých obcích

2.4 Vizualizace dat o mobilitě

2.4.1 Základní kartografické metody vizualizace dat

Studie autorů Ahas et al. (2007) analyzovala sezonní změny turismu v Estonsku s využitím mobilních dat. Využili explorativní faktorové analýzy pro rozdělení sezonní mobility do čtyř hlavních faktorů. K vizualizaci těchto faktorů využili jednoduchých

kartogramů. Kartogramy umožnily identifikovat hlavní oblasti s letním a zimním turismem, stejně tak oblasti s minimální a maximální turistickou aktivitou.

Novák (2010) ve svém výzkumu analyzoval prostorovou a časovou mobilitu obyvatel v českých městech na základě mobilních dat. Mezi stěžejní cíle jeho výzkumu patřila identifikace denních a týdenních vzorců mobility a tvorba typologie. Při realizaci uvedeného výzkumu byly využity různé vizualizační metody, mezi kterými byly kartodiagramy, časové řady a analýza trajektorií pohybu. Jak Novák shrnuje: „sekvenční lokalizační údaje jsou definovány jako časově uspořádaná posloupnost jednotlivých lokalizačních bodů, na jejichž základě je pak možné vytvářet a analyzovat dráhy pohybu objektu v prostoru“ (Novák, 2010). Výše popsaná metoda poskytla detailní přehled o hlavních trasách pohybu obyvatel během dne. Výsledky naznačily, že mobilita vykazuje ranní a odpolední špičky. Kartodiagramy umožnily zobrazit prostorové rozložení intenzity dojížděky mezi jednotlivými oblastmi. Díky těmto vizualizacím bylo možno identifikovat klíčové dopravní tahy a uzly. Ze závěrů studie lze uvozovat, že většina tras je stabilní a opakuje se v pravidelných intervalech. Celkově lze shrnout, že základní kartografické metody, ač jsou jednoduché a nedokážou pojmout vše, stále mohou při analýzách mobility představovat velmi užitečný nástroj.

2.4.2 Heat-mapy a animace

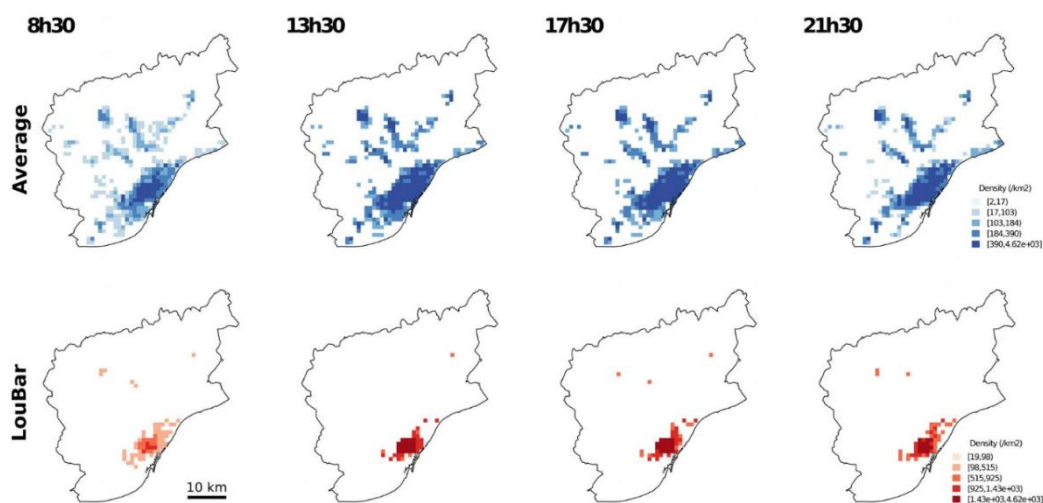
Kromě základních vizualizačních technik, jež byly zmíněny výše využívají studie i pokročilejší techniky umožňující hlubší analýzy a interaktivní prezentace dat. Mezi tyto metody patří například heat-mapy, animace či dynamické vizualizace. Heat-mapy umožňují identifikovat místa s největší koncentrací pohybu a zároveň vizuálně znázornit intenzitu mobility v různých oblastech.

Wei et al. (2023) se zaměřili na hodnocení prostorově-časové distribuce populace ve městě Xining v Číně, a to na základě mobilních dat. Heat-mapy zde byly využity k vizualizaci hustoty pohybu obyvatelstva, což umožnilo identifikaci oblastí s vysokou a nízkou koncentrací osob. Výsledky studie potvrdily, že heat-mapy umožňují rychlou a méně náročnou identifikaci prostorových vzorců. Autoři zdůrazňují, že „data mobilních telefonů mají výhodu v reálném čase, dynamice a ve vysokém rozlišení“, (Wei et al., 2023).

Studie autorů Vanhoof et al. (2018) se zaměřila na výzkum pohybu obyvatel. Autoři identifikovali „hot spots“ (hustě obydlené oblasti) a „cold spots“ (méně aktivní oblasti), a to v průběhu různých časových období. Bylo zjištěno, že časové faktory výrazně ovlivňují prostorovou distribuci populace. Autoři uvádějí, že v srpnu detekované hotspoty ilustrují jasné shluky vysokého počtu domácích lokalit v blízkosti mořských a horských oblastí. „To je v kontrastu s očekávaným prostorovým vzorem, kde se v blízkosti měst a v městských oblastech nacházejí vysoké shluky počtu obyvatel“ (Vanhoof et al., 2018).

Ačkoliv se všechny výše popsané studie přímo zabývají vizualizacemi mobilních dat, existují rovněž výzkumy, jež se nezaměřují přímo na mobilní data, ale přinášejí užitečné poznatky a přístupy k vizualizacím. Kouborov et al. (2011) ve své studii zjistili, že kombinace heat-map a animací zvyšuje přístupnost dat. Autoři navrhli metodu GMap, která umožňuje vizualizaci dynamických prostorových vzorců. Jmenovaná metoda poskytuje způsob interpretace dat prostřednictvím kombinace barev a animovaných změn. Uvedené přístupy mohou být zvláště nápomocné a relevantní, pokud je cílem komunikace dat široké veřejnosti a interpretace musí být co nejjednodušší. Výsledky naznačily, že animace sice zvyšují atraktivitu vizualizací, ale nejsou vždy vhodné pro přesnou analýzu dat. Nejefektivnější přístup je dle autorů kombinace heat-map a animací. Pro konkrétní detaily změn v prostoru a čase jsou efektivnější heat-mapy, pro zobrazení více obecných

faktů, například celkových trendů je vhodné využít animace. „Animace není příliš vhodná pro analýzu dat, ale často je zábavná a vzrušující“ (Kouborov et al., 2011).



Obrázek 1 – Vizualizace lokalizace hotspotů při použití dvou různých kritérií pro město Barcelona (Louail et al.2014)

2.4.3 Interaktivní dashboardy

V neposlední řadě lze shrnout, jakou roli hrály interaktivní mapy a dashboardy při monitorování šíření viru COVID-19. Jedním z nejvýznamnějších vizualizačních nástrojů během pandemie COVID-19 byl Dashboard od Univerzity Johnse Hopkinse. Tento nástroj byl vyvinut Centrem pro systémy vědy a inženýrství (CSSE), na univerzitě Johnse Hopkinse (JHU) a poskytoval globální data o počtu potvrzených případů nákazy, úmrtí a zotavení. Všechna data byla zobrazena na dynamické mapě v reálném čase. Ačkoliv JHU Dashboard nevyužíval přímo mobilní lokalizační data, jeho vizualizace byla často kombinována s analýzami mobility obyvatelstva, jež byly založeny na datech od firem Google, Apple a Facebook. Díky těmto analýzám bylo snazší přizpůsobit opatření aktuální situaci a omezit šíření viru. Efektivní vizualizační metody, které se osvědčily u pandemických dashboardů můžeme využít i na mobilní lokalizační data. Interaktivní mapové vizualizace v kombinaci s mobilními daty mohou uživateli umožnit filtrovat data dle regionů či časových období. Animace a časové řady mohou ukazovat změny v pohybu obyvatel během různých scénářů. Dále umožnění sledování mobilních trendů může zpřesnit rozhodování. „Dashboardy jsou tvořeny z více vizualizací, které jsou v ideálním případě kombinované tak, aby poskytovaly efektivní přehled o datech.“ (Crisan, 2022). Uvedený přístup podtrhuje důležitost vizualizace nejen jako analytického nástroje, ale také jako prostředku pro efektivní komunikaci dat široké veřejnosti a odborníkům.

Možnosti využití vybraných metod ve vlastní práci

Na základě literární rešerše a charakteru mobilních dat společnosti Vodafone se pro účely této práce jeví jako nejvhodnější následující metody vizualizace:

- **explorační prostorová analýza:** umožní prozkoumat data a určit základní složení populace v konkrétních obcích, dále srovnat různá časová období a výsledky vizualizovat v grafické či tabelární podobě. Jediné omezení spočívá v tom, že lze vybírat pouze pár reprezentativních vzorků a kvůli tomu se s interpretacemi musí pracovat velmi opatrně

- **heat-mapy:** vhodné pro zobrazení koncentrací pohybu obyvatel v prostoru a čase, což může být zásadní pro zjištění dynamiky konkrétních obcí. Dále umožňují identifikovat denní a sezónní vzorce a jejich prostorové rozložení
- **kartogramy a kartodiagramy:** umožní porovnat jednotlivé kategorie osob napříč územími a přehledně vizualizovat intenzitu a strukturu mobility s důrazem na prostorovou složku

Interaktivní dashboardy, příběhové mapy (Storymaps): umožní publikovat výsledky ve webovém prostředí a přidat interaktivitu výstupů pro větší funkcionalitu a přehlednost všech výstupů.

3 METODY A POSTUP ZPRACOVÁNÍ

3.1 Použité metody

V rámci této práce byly využity obecně teoretické i kvantitativní metody. Po základním čištění a transformaci dat byla provedena explorační analýza, jejímž cílem bylo identifikovat sezónní trendy, typické vzorce a rozdíly v rozložení jednotlivých kategorií osob v čase a prostoru. Následně byla pomocí lokálního Moranova indexu provedena analýza prostorové autokorelace, která umožnila odhalit významné prostorové shluky a odlehle hodnoty (outliery).

Na základě kombinace všech poznatků a multivariační shlukové analýzy pak byla sestavena typologie obcí a katastrálních území. Nakonec byla data mobilních operátorů Vodafone validována pomocí referenčních dat ze SLDB 2021 a doplňkové datové sady z portálu kamdojizdime.cz.

3.1.1 Explorační analýza dat (EDA)

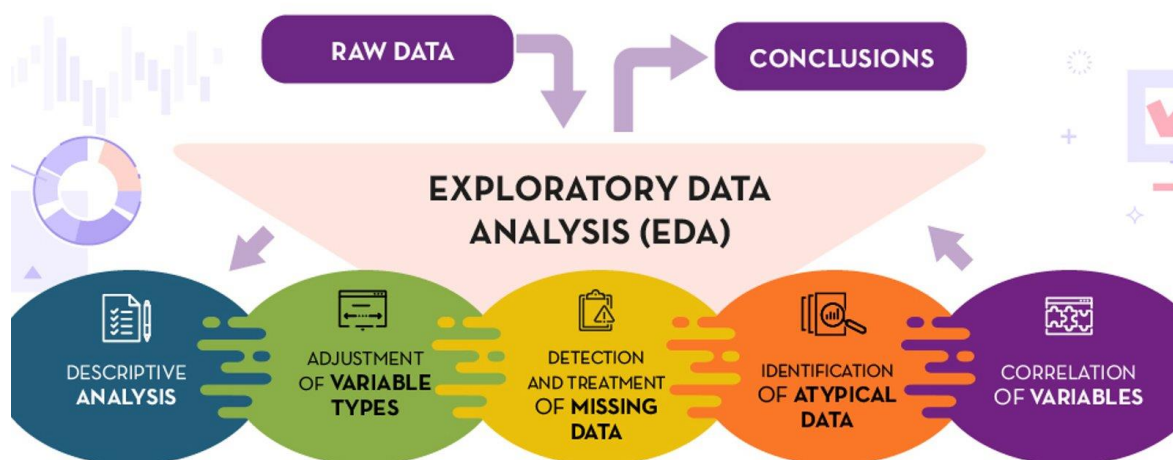
EDA je přístup k analýze dat, který využívá především vizualizační a deskriptivní metody ke zkoumání obecné struktury dat, odhalování typických vzorců, anomálií, outlierů či vztahů mezi proměnnými. Zároveň tento přístup není vázán na předem stanovené hypotézy (Tukey, 1977). Zmíněný přístup byl poprvé popsán Johnem Tukeym v roce 1977, který jej popsal jako "detektivní práci s daty—numerickou detektivní práci—počítací detektivní práci—nebo grafickou detektivní práci." (Tukey, 1977). Na rozdíl od jiných přístupů, např. konfirmační analýzy, jež se soustředí na pokročilejší analýzy či statistické testy, EDA klade důraz na pochopení vzorců v datech formou vizuálního zkoumání (Hoaglin, Mosteller & Tukey, 1983).

Hlavním cílem EDA je poskytnout co nejvíce informací o datech ještě předtím, než budou podrobně analyzovány. Výsledná zjištění lze pak využít pro výběr vhodných analýz a předmětu zkoumání. Tukey zdůrazňoval, že vizualizace jsou klíčové pro identifikaci různých charakteristik dat, mezi ně patří identifikace trendů, sezonnost, či anomálie a outlierů.

Behrens v roce 1997 definoval EDA jako: "soubor technik, které maximalizují vzhled do datové sady, odhalují její vnitřní strukturu, identifikují extrémy a testují základní předpoklady." (Behrens, 1997). Pokud je k dispozici velké množství dat a není jednoznačné kde a jak začít, lze považovat EDA za skvělý přístup, jak začít.

Typickými nástroji EDA jsou vizualizační techniky, jako jsou histogramy, box-ploty, scatter-ploty, heat-mapy či Q-Q ploty, které umožňují rychle identifikovat základní charakteristiky dat. Kromě toho lze využít i jednoduché numerické přehledy – průměr, medián, kvartily nebo korelační koeficienty. Tyto přístupy poskytují doplňující informace o vztazích mezi proměnnými. V rámci EDA se často provádí i základní čištění dat, například identifikace chybějících hodnot nebo korekce zjevných nesrovnalostí.

Ačkoliv EDA neposkytuje definitivní odpovědi ani formální závěry, hraje klíčovou roli při orientaci v datech a formulaci hypotéz pro další analýzu. Její hlavní přínos spočívá v možnosti intuitivního a flexibilního přístupu k datům, který umožňuje analytikovi rozhodnout, jaké další kroky a metody budou v konkrétním případě nejvhodnější. Průběh explorační analýzy shrnuje Obrázek 2.



Obrázek 2 – Diagram znázorňující průběh explorační analýzy

3.1.2 Prostorová autokorelace

Prostorová autokorelace je statistická vlastnost geografických dat, která měří vztah mezi hodnotami jedné proměnné v závislosti na jejich prostorové blízkosti. Jednoduše určuje, zda jsou podobné hodnoty v prostoru shlukovány, rozptýleny, nebo rozloženy náhodně (Anselin, 1995). Getis & Ord (1992) popisují prostorovou autokorelaci jako „vztah mezi hodnotami geografické proměnné v sousedních prostorových jednotkách, který lze kvantifikovat pomocí prostorových vah a testovat pomocí statistických metod.“ (Getis & Ord, 1992).

Prostorová autokorelace může být dvojího typu, globální či lokální, a to v závislosti na tom, zda je analyzováno celkové rozložení hodnot v prostoru, což řeší metoda globální, nebo zda jsou analyzovány konkrétní prostorové jednotky a identifikovány lokální shluky a outliery, v tom případě se jedná o metodu lokální autokorelace.

Lokální Moranův index je jednou s nejpoužívanějších metod analýzy lokální prostorové autokorelace. Tento index byl vyvinut Lucem Anselinem v roce 1995. Díky zmíněnému indexu lze kvantifikovat prostorovou závislost konkrétních jednotek v rámci většího území a identifikovat oblasti s konkrétními prostorovými vzory. Anselin definuje lokální Moranův index jako „lokální indikátor prostorové asociace, který umožňuje detekovat shluky vysokých nebo nízkých hodnot a prostorové odlehle hodnoty (outliery) v geografických datech.“ (Anselin, 1995). Vzorec pro výpočet lokálního Moranova indexu:

$$I_i = \frac{x_i - \bar{x}}{m_2} \sum_{j=1}^N w_{ij} (x_j - \bar{x})$$

- I_i je lokální Moranův index pro prostorovou jednotku i
- x_i a x_j jsou hodnoty zkoumané proměnné v jednotkách i a j
- \bar{x} je průměrná hodnota proměnné v celém území
- S^2 je rozptyl hodnot
- w_{ij} je prostorová váha mezi jednotkami i a j

Výsledné hodnoty lokálního Moranova indexu se často vizualizují pomocí tzv. LISA map (Local Indicators of Spatial Association), které znázorňují prostorové vztahy mezi hodnotami proměnné v dané jednotce a jejími sousedy. Cílem LISA mapy je identifikovat oblasti s významnou prostorovou autokorelací – tedy kde se podobné nebo naopak kontrastní hodnoty vyskytují pohromadě. Tyto vztahy se obvykle dělí do čtyř základních kategorií:

- **High-High (HH)** – prostorové shluky vysokých hodnot obklopených jinými vysokými hodnotami, často označované jako hotspots
- **Low-Low (LL)** – prostorové shluky nízkých hodnot obklopených jinými nízkými hodnotami, někdy označované jako coldspots
- **High-Low (HL)** – jednotky s vysokou hodnotou obklopené jednotkami s nízkými hodnotami, označované jako prostorové odlehlé hodnoty (spatial outliers)
- **Low-High (LH)** – jednotky s nízkou hodnotou obklopené jednotkami s vysokými hodnotami, rovněž představující prostorové odlehlé hodnoty

Další metody lokální prostorové autokorelace, které stojí za zmínku jsou:

- **Getis-Ord G_i^* (1992)** – využívá se k detekci hotspotů a coldspotů, rozdíl mezi lokálním Moranovým indexem je v přístupu k normalizaci dat. Zatímco lokální Moranův index využívá normalizaci hodnot průměrem, metoda Getis-Ord G_i^* normalizaci nevyužívá, což vede k odlišné identifikaci prostorových shluků.
- **Lokální Gearyho koeficient (1954)** – využívá se jako alternativa k lokálnímu Moranovu indexu. Zatímco lokální Moranův index násobí rozdíly hodnot mezi jednotkami, Gearyho koeficient kvantifikuje absolutní rozdíly mezi jednotkami, což je citlivější na heterogenní vzory v datech.

3.1.3 Shluková analýza (multivariate clustering)

Shluková analýza je statistická metoda, která umožňuje automatické seskupování objektů na základě více proměnných současně. Tento přístup umožňuje identifikovat přirozené shluky, kde objekty v rámci jednoho shluku sdílejí stejné nebo podobné vlastnosti, zatímco mezi jednotlivými shluky jsou rozdíly co nejvýraznější (Everitt et al., 2011).

Shluková analýza se využívá napříč mnoha disciplínami včetně geoinformatiky, marketingu, sociálních věd, nebo biostatistiky (Kaufman & Rousseeuw, 2005) a lze ji provést například v programu ArcGIS Pro, kde využívá K-means nebo K-medians algoritmus, což jsou jedny z nejpoužívanějších přístupů ke shlukové analýze.

Algoritmus K-means, představený MacQueenem (1967) minimalizuje rozptyl v rámci shluků a přiřazuje objekty do K předem definovaných shluků na základě jejich euklidovské vzdálenosti k průměru shluku neboli centroidu.

K-Medoids shlukování je varianta K-means, která místo euklidovské vzdálenosti využívá tzv. „Manhattanskou“ vzdálenost a jako centroid používá medián. Zmíněný přístup se více hodí pro heterogenní data, jelikož je méně citlivý na extrémní hodnoty.

Mezi další alternativy patří hierarchické shlukování, DBSCAN a Gaussian Mixture Models (GMM), které jsou užitečné pro složitější datové struktury (Jain et al., 1999).

3.1.4 Typologie

Typologie je vědecká metoda, která se zabývá rozčleněním soustavy objektů a jejich seskupováním na základě společných vlastností do zobecněných kategorií či typů. Tento

přístup umožňuje systematické třídění objektů či jevů, což usnadňuje jejich studium a porozumění jejich vzájemných vztahů (Hampl, 2007).

Typologie nachází uplatnění v široké škále oborů či vědních disciplín včetně literárních věd, informačních věd, literárních teorií, také pak v geoinformatice a statistice.

V této práci byla typologie využita pro kategorizaci různých skupin osob na základě jejich prostorového a časového chování. Zmíněná klasifikace umožnila následné seskupení obcí a katastrálních území do skupin dle typického chování jejich obyvatel. Tento přístup umožňuje lépe pochopit dynamiku pohybu populace a identifikovat vzory v distribuci obyvatelstva.

3.2 Použitá data

Mobilní lokalizační data od mobilního operátora Vodafone

Mobilní lokalizační data od operátora Vodafone byla poskytnuta ve čtyřech datových sadách označených jako A–D. Jedná se o agregovaná a anonymizovaná signalizační data získaná z mobilní sítě, která byla dále zpracována a klasifikována dle typu pohybu a chování SIM karet. Pro účely této práce byly využity sady A, B a D.

- Sada A obsahuje informace o rezidentech, dále rozlišených na vyjíždějící a nevyjíždějící a také o návštěvnicích, vždy jednu průměrnou hodnotu za dané období pro každou obec.
- Sada B obsahuje informace o výskytu SIM karet v jednotlivých územích, agregované po hodinách a dnech v týdnu (pondělí až neděle). Hodnoty představují průměr ze čtyř dnů, které byly vybrány ze sledovaného období a slouží k vytvoření modelového týdenního cyklu. Data jsou klasifikována podle vztahu SIM k území – rozlišují se rezidenti, návštěvníci a osoby s kotevním bodem typu práce/škola
- Sada C (OD matice) nebyla využita.
- Sada D obsahuje dojížděkové vztahy mezi obcí bydliště a cílovou obcí, rozdělené dle typu cesty na dojížděku za prací/školou a návštěvu. Významné je, že jako jediná z datových sad obsahuje město Olomouc jako jednu obec, nikoliv rozdělenou na katastrální území.

Všechny sady byly poskytnuty ve formátu SHP pro každý typ osoby a období, a pokrývají území Olomouckého kraje a obcí ve vzdálenosti do 10 km od jeho hranic. K dispozici byla čtyři období:

- Léto 2020: 1. 8. – 28. 8.
- Podzim 2020: 6. 10. – 10. 11.
- Léto 2022: 23. 7. – 19. 8.
- Podzim 2022: 10. 10. – 6. 11.

Z metodického hlediska jsou data založena na identifikaci tzv. kotevních bodů – míst, kde se SIM karta vyskytuje opakovaně v určitých časech. Na základě frekvence a denní doby výskytu jsou těmto bodům přiřazeny funkce (např. bydliště, pracoviště, návštěva). SIM karta je poté klasifikována podle převažujícího typu chování a zařazena do odpovídající kategorie.

Výsledná data jsou agregována na úroveň obcí, anonymizována metodou differential privacy a zaokrouhlena tak, aby nebylo možné identifikovat konkrétního uživatele. Položky s malým počtem uživatelů (např. méně než pět SIM v případě průměrů) byly zaokrouhleny na nulu nebo z výstupu zcela odstraněny.

Data z portálu Kamdojízíme.cz

Portál Kamdojizdime.cz poskytuje agregovaná data o mobilitě obyvatelstva na základě signalizačních dat všech tří hlavních mobilních operátorů v ČR (O2, T-Mobile a Vodafone). Data byla zpracována společností INTENS Corporation s.r.o. v rámci projektu Ministerstva vnitra ČR a rozdělena do čtyř finálních datových sad (FD1 až FD4), pokrývajících různá časová období.

V rámci této práce byla využita výhradně sada FD3, konkrétně tabulky 3 a 3.1, které obsahují hodinové hodnoty přítomného obyvatelstva v jednotlivých obcích během dne. Ostatní datové sady (FD1, FD2 a FD4) nebyly využity. Pro účely analýzy byla využita pouze kategorie „rezidenti“, a to za období léta 2022 (18. 7. – 14. 8. 2022), které zahrnuje 28 vybraných, metodicky očištěných dní.

Data jsou založena na detekci pohybových vzorců SIM karet, přičemž každé SIM je na základě chování přiřazen jeden dominantní příznak (např. domov, návštěva, dojíždka). Použita je hierarchická klasifikace pobytových míst a každá SIM je přiřazena vždy jen jedné obci jako „domovské“.

Soubor SIM byl před zpracováním očištěn od SIM bez souhlasu ke zpracování (včetně zahraničních nebo virtuálních operátorů), dále od neaktivních nebo technických SIM a zároveň byly započítány pouze SIM aktivní alespoň ve 14 z 28 dnů sledovaného období.

Následně byly aplikovány korekční koeficienty, konkrétně koeficient podílu osob bez SIM karty, koeficient korekce za podíl virtuálních operátorů, kteří nejsou v datech přímo zastoupeni a dále byla vytvořena projekce na celkovou populaci pomocí údajů ČSÚ. Výstupy tedy neodpovídají přímo počtu SIM, ale jsou demograficky korigovány a projekčně dopočteny na reálnou populaci.

ArcČR 4.3 – Digitální vektorová databáze České republiky. Obsahem jsou data administrativního členění České republiky propojená s vybranými statistickými údaji Českého statistického úřadu ze Sčítání lidu, domů a bytů ÚAP, turismus a naděje dožití. Zdrojem geometrie dat jsou data z RÚIAN (Registru územní identifikace, adres a nemovitosti) exportovaná k 1. 1. 2024. Primárním souřadnicovým systémem je S-JTSK / Krovák East-North (EPSG: 5514). Měřítko vrstev se pohybuje v rozmezí 1:500 000 až 1:10 000 v závislosti na konkrétní vrstvě.

ArcČR 500, verze 3.3 – Digitální geografická databáze České republiky v měřítku 1:500 000. Obsahuje vektorová data pokrývající geografické prvky, administrativní členění a statistické ukazatele dále také rastrová data zahrnující digitální model reliéfu a stínovaný reliéf. Data jsou ve formátu Esri File Geodatabase (GDB) a byla vydána v říjnu 2016. Primárním souřadnicovým systémem je S-JTSK / Krovák East-North (EPSG: 5514).

3.3 Použité programy

ArcGIS Pro 3.1.3 – program pro veškeré geo-statistické analýzy a tvorbu mapových výstupů

ArcGIS Online – Storymaps – on-line prostředí pro vizualizaci výsledků práce

Python 3.12.3 – prostředí pro práci s daty a tvorbu grafických výstupů

Použité knihovny: pandas, numpy, matplotlib, seaborn, re, statsmodels.api

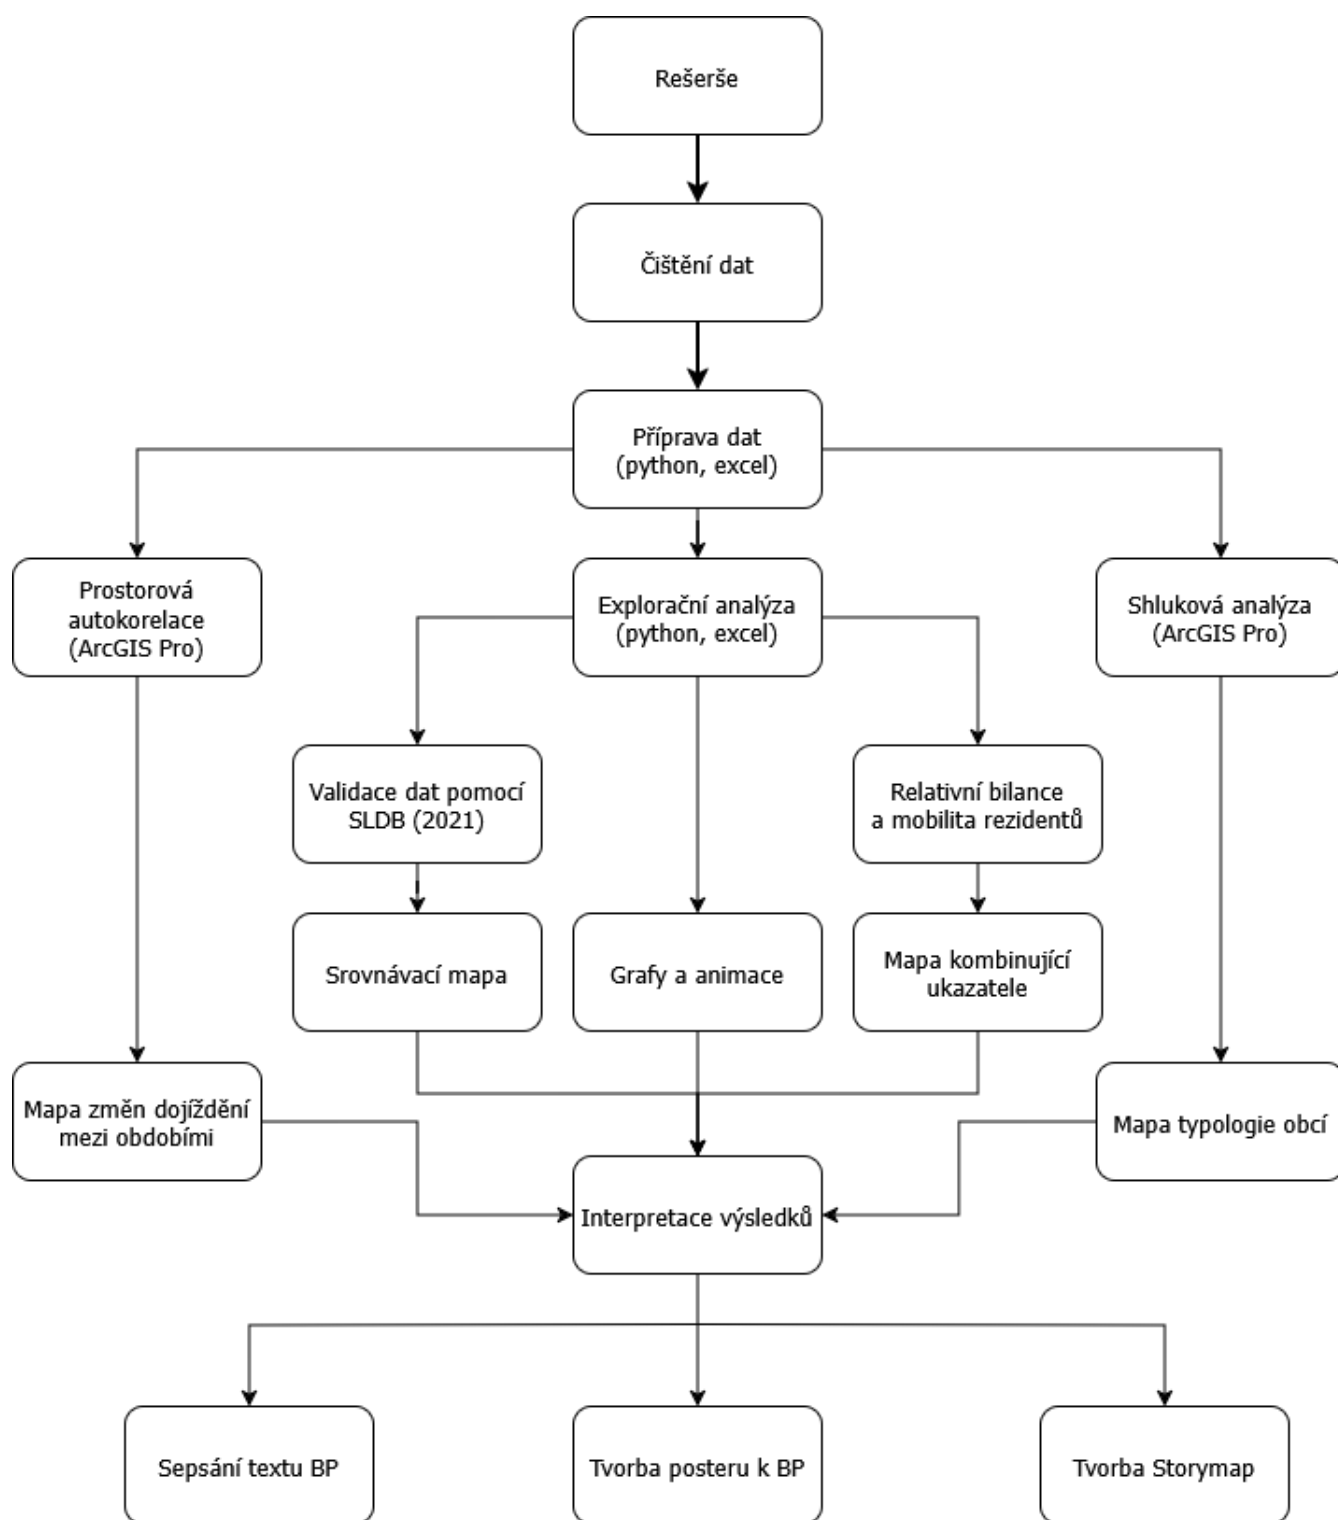
Microsoft excel – program pro čištění a transformaci dat, tvorbu základních statistik a další práci s daty

ChatGPT 4.0 – on-line nástroj pro optimalizaci skriptů v Pythonu a úpravu textu práce

Canva online – on-line nástroj pro tvorbu a úpravu grafických výstupů

Capcut – video editor, pro dodatečné zpracování animací

Postup zpracování – viz Obrázek 3



Obrázek 3 – Diagram znázorňující postup práce

4 EXPLORAČNÍ ANALÝZA

Cílem je představit analytický přístup, který byl zvolen pro hlubší porozumění prostorové a časové distribuce obyvatelstva na základě dat od mobilního operátora Vodafone. Důraz byl kladen na návrh vhodných metod zpracování, přepočtu a vizualizace těchto dat. Pro zmíněné účely byla využita výhradně datová sada B, obsahující časové řezy (viz Kapitola 3)

Před zahájením komplexnějších analýz bylo nutné zvolit vhodný přístup pro efektivní zpracování a interpretaci velkého množství dat. Z tohoto důvodu byla použita explorační analýza dat (EDA), která slouží k vizuálnímu i kvantitativnímu zachycení základních vzorců, sezónních trendů a odchylek v datech. Předzpracování a základní práce s daty byly realizovány v prostředí Microsoft Excel, zatímco pokročilejší výpočty a veškeré vizualizace byly prováděny pomocí skriptů v jazyce Python.

Mezi hlavní cíle této analýzy patřilo porovnání stavů obyvatelstva ve vybraných obcích a katastrálních územích mezi obdobím pandemie a post-pandemie, dále zachycení sezónních změn mezi létem a podzimem a vyjádření denní či týdenní dynamiky pohybu osob. Prvním krokem byl výběr reprezentativních obcí, které slouží jako základ pro následnou interpretaci.

Výběr těchto obcí byl proveden na základě jejich známých prostorových, funkčních a demografických charakteristik. Zohledněna byla logika prostorové struktury osídlení i očekávané rozdíly v chování jednotlivých kategorií osob. Zde jsou shrnuty hlavní argumenty pro výběr:

- větší obce zpravidla vykazují větší podíl dojíždějících, jelikož často fungují jako průmyslová či ekonomická centra
- obce v horských oblastech mají zpravidla vyšší počet návštěvníků, hlavně během letního období a často fungují jako turistická centra
- menší obce obvykle nevykazují výraznou dominanci některé z kategorií a mají většinou stabilní rezidenční charakter
- dopravní uzly či přestupní místa bývají často zatíženy intenzivnější dojížděnkou
- obce v blízkosti větších měst často fungují jako satelitní městečka či příměstské zóny s vyšší vyjížděnkou za prací a do škol, tedy i s vyšším počtem rezidentů

4.1 Porovnání denního režimu různých kategorií osob

Cílem bylo porovnat denní a také týdenní režim různých kategorií osob mezi létem a podzimem a tím sledovat sezónní proměnlivost jednotlivých obcí. Zároveň byla pozornost věnována rozdílům mezi obdobím pandemie a obdobím po jejím odeznění. Tím se práce snažila naplnit jeden z cílů práce – zachytit dynamiku prostorového rozložení obyvatelstva prostřednictvím hodinových a denních variací a porovnat rozdíly způsobené různými časovými obdobími.

Pro tuto analýzu byly zvoleny liniové grafy, které umožňují přehledně sledovat vývoj počtu osob během dne a zároveň efektivně porovnávat průběh mezi jednotlivými obdobími. Oproti heat-mapám využitým v následující kapitole (viz 4.2) jsou vhodnější pro znázornění čistě časové dynamiky, zejména pokud je cílem porovnat více časových řezů najednou. Liniový graf umožňuje lépe číst konkrétní hodnoty i trendy, zatímco u heat-mapy je intenzita vyjádřena barvou, což může ztížit interpretaci menších rozdílů.

Do analýzy byly zahrnuty dvě obce – Olomouc a Prostějov. Olomouc byla zvolena kvůli jejímu postavení jakožto regionálního centra, kde by mělo dominovat více kategorií zároveň, ačkoliv byla dostupná na úrovni katastrálních území a byla nutná její agregace na úroveň

obce. Prostějov pak jako zástupce regionálního dojížděkového centra. Pro každou obec byly analyzovány tři kategorie osob: rezidenti, dojíždějící a návštěvníci.

Pro analýzu byla využita všechna dostupná období. Hodinová data za každý den jednoho týdne byla již v tomto formátu poskytnuta v datové sadě. Pro vytvoření grafů byl použit aritmetický průměr počtu osob v dané kategorii za jednotlivé hodiny, vypočtený jako průměr ze všech dnů v týdnu. Pro každou hodinu byla nejprve sečtena hodnota ze všech sedmi dní (pondělí až neděle) a výsledek následně vydělen sedmi. Tím vznikl reprezentativní denní průběh, který eliminuje vliv výkyvů v jednotlivých dnech a umožňuje lépe sledovat typické chování dané skupiny. Veškeré výpočty a vizualizace byly vytvořeny pomocí skriptu v prostředí Python.

Z vytvořených tří grafů byl pro detailní interpretaci vybrán graf znázorňující denní režim dojíždějících v Prostějově (viz Obrázek 4), který dobře vystihuje typický pracovní rytmus a zároveň ilustruje sezónní i pandemické změny. Ostatní grafy lze najít v Příloze 5 (denní dynamika návštěvníků) a Příloze 6 (denní dynamika rezidentů) Výsledky z Prostějova lze vzhledem k jeho funkci částečně zobecnit na další obce s podobným charakterem.

Interpretace denní dynamiky dojíždějících (obec Prostějov)

Graf (viz Obrázek 4) zobrazuje průměrný počet dojíždějících do obce Prostějov v jednotlivých hodinách dne pro zmíněná čtyři období. Na první pohled je patrný výrazný rozdíl mezi létem a podzimem, který ukazuje na sezónní vliv. Podzimní období vykazuje vyšší počet dojíždějících než letní, což odpovídá návratu k běžnému pracovnímu režimu po prázdninách.

Nejvíce dojíždějících je zaznamenáno v podzimním období roku 2020, tedy během pandemie COVID-19, což je překvapivé zjištění. Obecně se totiž očekává, že mobilita v době pandemických opatření klesá. Možným vysvětlením může být fakt, že v daném období ještě nebyla plošná opatření plně zavedena, nebo nebyla dostatečně důsledně dodržována. Rovněž může hrát roli lokální specifikum pracovního režimu v regionu.


Druhé nejvyšší hodnoty vykazuje podzim 2022, což odpovídá očekávanému nárůstu dojížděky v post-pandemickém období. Naopak nejnižší hodnoty jsou patrné v létě 2020, což lze logicky vysvětlit kombinací letních prázdnin a přetrvávajících restrikcí. I v létě 2022 je dojížděka nižší než na podzim, ale vyšší než v roce 2020, což potvrzuje postupný návrat k normálu.

Denní průběh se ve všech obdobích výrazně neliší. Typicky dochází k nárůstu počtu dojíždějících od páté hodiny ranní, špička nastává mezi osmou a 11. hodinou, poté následuje pozvolný pokles. V odpoledních hodinách od 13. hodiny počet dojíždějících

setrvale klesá, což odráží odjezd pracovníků zpět domů. Rozdíly mezi obdobími jsou tedy patrné zejména v celkových hodnotách, méně už ve tvaru denního průběhu.

Z těchto výsledků vyplývá, že dojíždka v Prostějově vykazuje stabilní rytmus odpovídající pracovnímu režimu, přičemž její intenzita kolísá podle ročního období, v menší míře i v závislosti na vnějších faktorech, jako byla pandemie. Lze předpokládat, že podobné vzorce by se vyskytovaly i v dalších městech se srovnatelnou funkcí v regionální struktuře.

DENNÍ DYNAMIKA DOJÍŽDĚJÍCÍCH VE MĚSTĚ PROSTĚJOV



Obrázek 4 - Liniový graf denní dynamiky dojíždějících ve městě Prostějov

4.2 Identifikace vzorů v distribuci kategorií osob

Cílem této části bylo zachytit opakující se vzory v denní a týdenní dynamice pohybu jednotlivých kategorií osob a zároveň porovnat rozdíly mezi různými obdobími. Tímto způsobem má práce snahu naplnit stanovený cíl zaměřený na identifikaci časových vzorců a proměnlivosti distribuce obyvatelstva.

Pro tuto analýzu byly zvoleny heat-mapy, které se ukázaly jako nejvhodnější nástroj pro vizualizaci dvou časových dimenzí současně, konkrétně dne v týdnu a hodiny během dne. Pomocí barevné škály je možné velmi rychle identifikovat časové intervaly s nejvyšší koncentrací osob a zároveň porovnat rozdíly mezi jednotlivými obdobími (např. mezi létem a podzimem nebo mezi pandemickým a post-pandemickým obdobím).

Na rozdíl od liniových grafů (viz Kapitola 4.1), které umožňují detailní sledování průběhu jedné časové řady napříč různými obdobími, poskytují heat-mapy komplexní a okamžitý přehled o vzorcích chování napříč celým týdnem. Jsou tedy výhodné zejména

při práci s rozsáhlými časovými řadami a více dimenzemi zároveň. Z těchto důvodů byly zvoleny jako hlavní forma vizualizace pro analýzu opakujících se časových rytmů a sezónních změn.

Do analýzy byly zahrnuty celkem 4 obce, které byly vybrány na základě jejich logických a geografických charakteristik jako reprezentanti různých typů osídlení a prostorového chování:

- **Velké Losiny a Jeseník** – turistické obec, vhodná pro analýzu návštěvníků
- **Prostějov** – regionální centrum s očekávanou intenzivní dojížděkou
- **Šumperk** – stabilní obec, vhodná pro práci s rezidenty

Pro každou z těchto obcí byla vytvořena dvojice heat-map zachycující denní a hodinový výskyt zvolené kategorie osob v různých obdobích. Jedná se pouze o výčet hodnot počtu přítomnosti osob v daných kategoriích a obdobích a nebyl zde prováděn žádný výpočet. Data obsahují hodinové hodnoty přítomnosti každé kategorie v daném období v období jednoho týdne, které vznikly průměrováním z celého měsíce. Pro obec Šumperk byla vytvořena heat-mapa ukazující relativní změnu rezidentů. V tomto případě již byl využit výpočet, a to konkrétně rozdíl mezi podzimem a létem pro obec Šumperk v roce 2022 a přepočítáno na procentuální hodnoty. Zpracování a vizualizace dat proběhlo v prostředí Python.

Pro detailní interpretaci byla vybrána obec Velké Losiny (viz Obrázek 5). Tato obec byla vybrána jako typický příklad sezónní destinace a slouží jako vhodný úvodní případ pro demonstraci přínosu vizualizace pomocí heat-map v kontextu časoprostorové analýzy. Také byla do ukázky přidána heat-mapa pro obec Jeseník (viz Obrázek 6), jako demonstrace určité anomálie. Všechny ostatní grafy lze najít v Příloze č. 2 (Prostějov) a Příloze č. 4 (Šumperk).

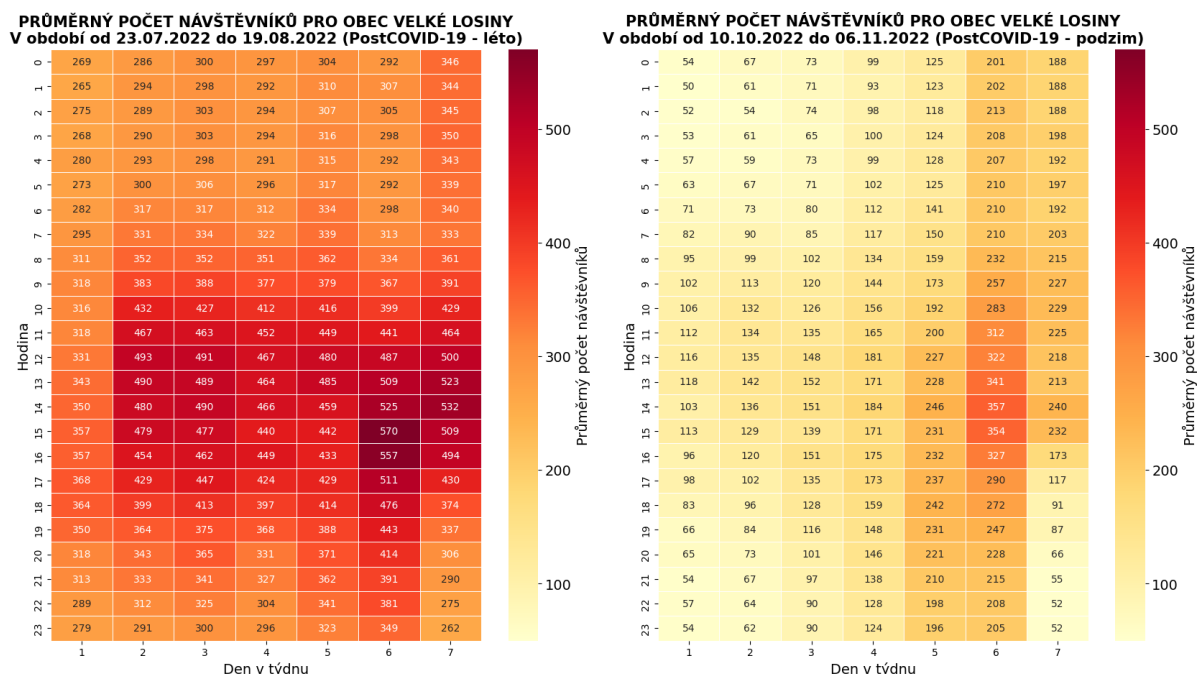
Interpretace vývoje návštěvnosti – Velké Losiny

Vizualizace zobrazuje průměrný počet návštěvníků v obci Velké Losiny v jednotlivých hodinách a dnech týdne pro dvě sezónní období – léto (23. 7. – 19. 8. 2022) a podzim (10. 10. – 6. 11. 2022). Z grafů je zřejmé, že letní období vykazuje stabilnější a obecně vyšší návštěvnost napříč celým týdnem. Nejvíce návštěvníků je v sobotu a pátek odpoledne, což je v souladu s předpokladem, že se jedná o víkendové pobyty spojené s rekreací. Naopak nejnižší hodnoty jsou v pondělí, což odpovídá době návratu návštěvníků zpět do zaměstnání či škol.

V podzimním období dochází k výraznému poklesu celkového počtu návštěvníků. Typicky se jedná o hodnoty mezi 50–300 osob za hodinu, zatímco v létě se maxima pohybují až kolem 530 návštěvníků za hodinu. I přes tento pokles však lze vysledovat výrazný víkendový nárůst. Pátek a sobota nadále patří mezi nejsilnější dny. Tento jev naznačuje stálý zájem o lokalitu i mimo hlavní turistickou sezónu, avšak nižší. Výrazně nižší návštěvnost v pracovní dny pak odráží fakt, že na podzim se lidé vrací zpátky k běžnému pracovnímu režimu a díky tomu nemají tolik příležitostí cestovat za rekreací a turistikou.

Z hlediska denní dynamiky je patrné, že v létě počet návštěvníků postupně narůstá od dopoledních hodin, vrcholí mezi 13. a 16. hodinou a následně klesá. V podzimním období se tento denní rytmus posouvá a vyrovnává. Je patrné, že špičky jsou méně výrazné, což může být důsledkem kratších dnů, horšího počasí nebo obecně nižší ochoty lidí cestovat na kratší výlety během pracovního týdne.

Z porovnání obou období vyplývá, že Velké Losiny mají výrazný rekreační charakter s dominancí víkendových návštěv, přičemž letní sezóna přitahuje výrazně více návštěvníků. Na základě těchto výsledků lze předpokládat, že podobné sezónní vzorce se dále vyskytují i v dalších menších obcích s turistickým zaměřením v horských oblastech.



Obrázek 5 – Porovnání počtu návštěvníků pro obec Velké Losiny mezi dvěma obdobími

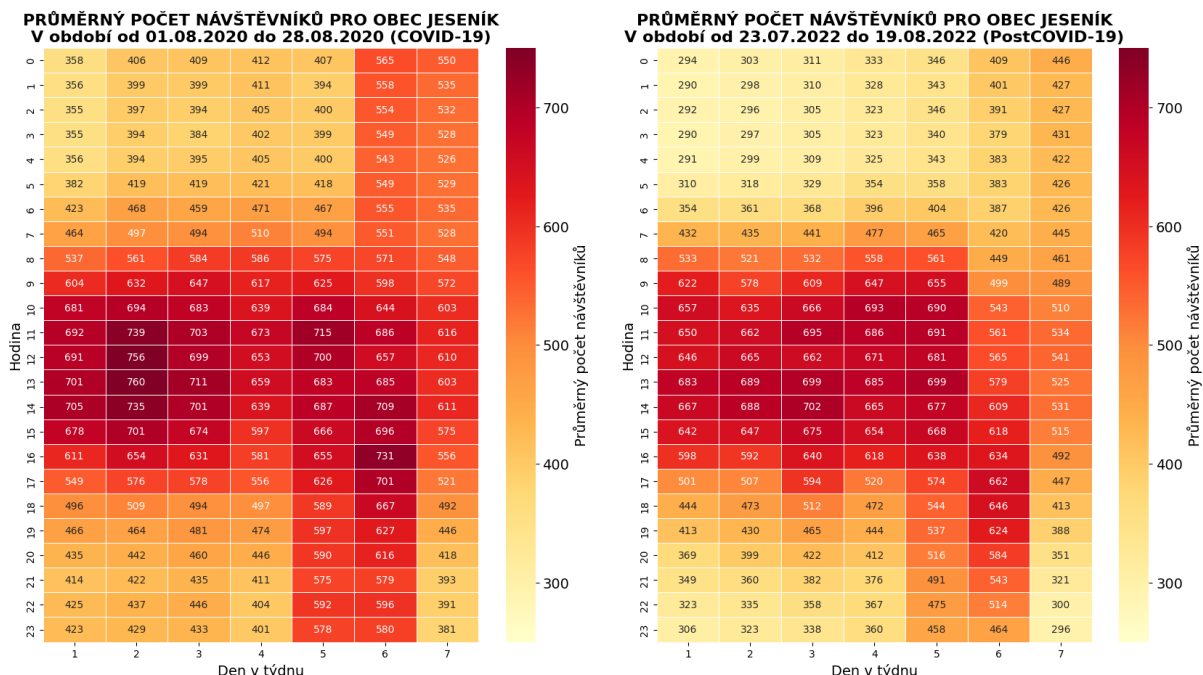
Obec Jeseník jako anomálie

Zatímco Velké Losiny reprezentují typický příklad sezónní destinace, Jeseník se jeví jako kontrastní případ (viz Obrázek 6), který se odlišuje od očekávaného vývoje. Obě obce mají podobný turistický charakter, ale v Jeseníku byl v období léta 2020 (během pandemie COVID-19) zaznamenán vyšší počet návštěvníků než v post-pandemickém létě 2022. Tento trend je v rozporu s obecnými předpoklady o poklesu návštěvnosti během pandemie.

Trend je zřejmý především v pracovních dnech mezi 11. a 17. hodinou, kdy se počet návštěvníků často pohybuje mezi 700–760 osobami, s maximem v úterý odpoledne. Naproti tomu v post-pandemickém období jsou hodnoty nižší a rozložení rovnoměrnější napříč týdnem.

Tento jev lze interpretovat jako důsledek přesunu lidí do přírody a na své chaty během období pandemie. Jeseník je známý množstvím rekreačních objektů a možnostmi dlouhodobého pobytu mimo městské prostředí. Oproti běžné sezónní návštěvnosti zde šlo pravděpodobně o delší pobyty než jen víkendové výlety. Vizualizace tak podtrhuje důležitost

kontextu při interpretaci dat a ukazuje, že i obce se stejným charakterem se mohou v různých obdobích chovat zcela odlišně.



Obrázek 6 - Porovnání počtu návštěvníků pro obec Jeseník mezi dvěma obdobími

4.3 Identifikace obcí s největšími změnami v mobilitě osob

Cílem bylo identifikovat obce, ve kterých došlo k nejvýraznějším změnám v přítomnosti osob mezi sledovanými obdobími – konkrétně mezi podzimem roku 2020 (období pandemie COVID-19) a podzimem 2022 (post-pandemické období). Analýza navazuje na předchozí kapitoly, které se věnovaly detailním časoprostorovým vzorcům vybraných obcí, a rozšiřuje pohled na úroveň celého regionu. Výsledky tak přinášejí širší kontext distribuce mobility v Olomouckém kraji a jeho okolí.

Pro zmíněné účely byly vytvořeny tři sloupcové grafy. První dva grafy srovnávají průměrný počet dojíždějících a návštěvníků ve vybraných obcích, rozdělené podle týdenního režimu na pracovní týden a víkend a sledovaného období. Třetí graf (viz Obrázek 7) se zaměřuje na obce s největším průměrným nárůstem počtu dojíždějících mezi dvěma podzimními obdobími (2020 a 2022), a byl vybrán pro detailní interpretaci, jelikož nejlépe vystihuje obecný trend návratu pracovní mobility po pandemii.


Agregace byla provedena dle typu dne – pracovní dny (pondělí až pátek) pro dojíždějící a víkend (sobota a neděle) pro návštěvníky. Díky agregaci byla pro každé období a obec vypočítána průměrná hodnota návštěvníků či dojíždějících. V případě třetího grafu byl vypočítán rozdíl průměrného počtu dojíždějících mezi podzimem 2020 a 2022 pro každou obec. Do grafu bylo následně zařazeno deset obcí s největším pozitivním rozdílem. Původně uvažovaná varianta přepočtu na relativní podíl byla nakonec zamítnuta – u obcí s nízkými absolutními hodnotami může i malý nárůst vést ke zkreslujícím procentuálním změnám. Práce s daty, výpočty a tvorba grafu proběhla v prostředí python. Ostatní grafy lze nalézt v Příloze č. 9 (dojíždějící) a v Příloze č. 10 (návštěvníci).

Interpretace výsledků – obce s největším nárůstem dojíždějících (2020 a 2022)

Graf (viz Obrázek 7) ukazuje deset obcí, kde byl mezi podzimem roku 2020 a podzimem roku 2022 zaznamenán nejvyšší nárůst průměrného počtu dojíždějících během pracovního týdne. Nejvýraznější změnu vykazuje město Kroměříž, kde došlo k nárůstu o 192 osob, následováno Boskovicemi a Holešovem. Výraznější nárůst zaznamenaly také menší obce jako Mohelnice, Bystrovany nebo Svitávka.

Tyto výsledky lze interpretovat jako důkaz návratu běžného pracovního režimu po pandemii, kdy došlo k obnovení dojížděky do zaměstnání a škol. Vyšší nárůst v menších nebo středních obcích může souviset s jejich napojením na větší městská centra nebo s obnovením provozu větších zaměstnavatelů, kteří byli v období pandemie omezeni.

Některé obce, jako například Jeseník nebo Šumperk, byly již zmíněny v předchozích kapitolách jako místa s výraznější dynamikou se zde opět objevují mezi nejvíce rostoucími, což potvrzuje jejich význam v rámci regionální mobility.




Obrázek 7 – Sloupcový graf znázorňující obce s největším průměrným nárůstem dojíždějících

Na základě všech zmíněných zjištění lze předpokládat, že do budoucna bude vhodné při sledování změn mobility věnovat pozornost nejen velkým městům, ale i menším obcím, které mohou být citlivé na vnější vlivy a proměny režimu práce a dopravy. Zjištěné výsledky zároveň potvrzují obecný trend návratu do běžného pracovního režimu po pandemii, a to nejvýrazněji v menších a středních sídlech, která jsou dopravně napojena na regionální centra. Ačkoliv Olomouc není mezi obcemi s největším absolutním nárůstem počtu dojíždějících, její význam je patrný v kontextu celého systému dojížděky – řada obcí s rostoucí mobilitou se nachází v jejím okolí, jako například Bystrovany nebo Litovel, což může odrážet obnovení vazeb na toto městské centrum.

4.4 Analýza vnitřní struktury populace obcí

Cílem bylo identifikovat typické vzorce složení populace v různých obcích a ověřit, zda odpovídají předpokládané charakteristice, která byla stanovena níže, např. rezidenční, návštěvnická, dojíždějící nebo vyjíždějící obec.

Data byla připravena a zpracována v prostředí Python, kde byly pro každou vybranou obec spočteny průměrné podíly jednotlivých kategorií osob zvlášť pro aktivní část dne (06:00–21:00) a noc (22:00–05:00), vždy ve dvou obdobích: podzim a léto 2022. Toto rozdělení bylo zvoleno záměrně, protože celodenní průměry bývají výrazně zkresleny noční převahou rezidentů, a tudíž mohou nepřesně zobrazovat skutečný denní podíl ostatních kategorií. Pro ilustraci tohoto zkreslení byl vytvořen doprovodný srovnávací graf pro podzimní období roku 2022 (viz Obrázek 8), který ukazuje procentuální rozdíl v podílu jednotlivých kategorií osob mezi celodenním průměrem a aktivní částí dne. Stejný graf byl vytvořen pro letní období roku 2022 (viz Příloha 11). Graf vznikl pomocí výpočtu procentuálních hodnot jednotlivých kategorií za celé dny a za aktivní část dne (06:00–21:00), následoval výpočet rozdílu mezi těmito dvěma průměry. Z grafu je zřejmé, že podíl rezidentů bývá v celodenním průměru nadhodnocený, zatímco podíly dojíždějících a návštěvníků jsou podhodnocené – rozdíl činí až 2,3 %. Největší odchylky jsou patrné ve všední dny, což potvrzuje nutnost rozlišovat mezi celodenním režimem a noční strukturou.



Obrázek 8 Sloupcový graf znázorňující procentuální rozdíl mezi celodenním průměrem a aktivní částí dne (podzim 2022)

Pro doplnění a zpřesnění interpretace, zejména v případě určení míry vyjíždění rezidentů, pro odlišení satelitních obcí byla využita i datová sada A, která obsahuje hodnoty podílu vyjíždějících a nevyjíždějících osob za práci a do škol. Je však důležité zdůraznit, že metodika tvorby obou datových sad není identická, a proto tyto výsledky nebyly přímo porovnávány. Sada A tedy sloužila pouze jako doplňková sada pro potvrzení výsledných struktur obcí. Na základě sady A byla vytvořena tabulka (viz Tabulka 2) pomocí programu Microsoft Excel, kde byly vypočítány procentuální hodnoty vyjíždějících a nevyjíždějících z rezidentů dle vzorců:

$$\text{podíl vyjíždějících(\%)} = \frac{\text{vyjíždějící}}{\text{rezidenti}} * 100$$

$$\text{podíl nevyjíždějících(\%)} = \frac{\text{nevyjíždějící}}{\text{rezidenti}} * 100$$

Podobně jako v předchozích kapitolách byly vybrány reprezentativní obce na základě jejich známých charakteristik nebo předpokládaného funkčního typu. Ke každé z nich byla přiřazena pracovní hypotéza, která očekávala určitý poměr jednotlivých kategorií osob. Následně byly v prostředí Python vytvořeny strukturní grafy, které ukazují rozložení osob v obci v aktivní a neaktivní části dne v letním a podzimním období. Pro každé období (léto a podzim) a část dne (den a noc) byl spočten relativní podíl tří skupin osob – rezidentů, dojíždějících a návštěvníků – na denním počtu osob. Výsledky byly vizualizovány jako sloupcové grafy v matici 2×2, přičemž každý sloupec znázorňuje procentuální zastoupení skupin během jednotlivých dnů v týdnu. Vytvořené výstupy umožnily zařadit obce do jednoho ze čtyř základních typů podle dominantního režimu mobility:

- **rezidenční obec**

Počet rezidentů zůstává stabilní mezi dnem a nocí. Typicky zde lidé bydlí i pracují a nedochází k výraznému poklesu rezidentů během dne.

- **dojíždějící obec**

Výrazný nárůst dojíždějících v aktivní části dne. Může být doprovázen mírným poklesem podílu rezidentů, zejména kvůli navýšení ostatních kategorií.

- **vyjíždějící obec**

Typicky dochází k poklesu podílu rezidentů během dne. Lidé často dojíždějí do větších měst za prací nebo studiem. Obce tohoto typu se často nacházejí v blízkosti větších měst.

- **návštěvnícká obec**

V aktivní části dne roste podíl návštěvníků, zatímco podíl rezidentů relativně klesá. Neznamená to však nutně, že rezidenti obec opouštějí, spíše je dočasně převládá návštěvníci.

Na základě dostupných informací a charakteru území byly jednotlivým obcím přiřazeny následující pracovní hypotézy:

- **Dolní Morava** – návštěvnícká obec, předpokládá se dominantní přítomnost návštěvníků přes den, zejména v létě
- **Jeseník** – návštěvnícká obec s možným kombinovaným režimem, očekáván nárůst návštěvníků přes den, zejména v létě
- **Hranice** – dojíždějící obec, očekáván vyšší podíl dojíždějících ve všední dny
- **Lutín** – dojíždějící obec, předpokládán nárůst dojíždějících a pokles podílu rezidentů přes den
- **Velký Týnec** – rezidenční obec, očekává se stabilní přítomnost rezidentů mezi dnem a nocí
- **Křelov-Břuchotín** – rezidenční nebo vyjíždějící obec, očekává se vyšší podíl vyjíždějících přes den

Hypotéza byla následně ověřena pomocí vytvořených vizualizací a doplněna hodnotami z datové sady A. V této podkapitole bude podrobně interpretován jeden vybraný příklad, kterým je obec Dolní Morava (viz Obrázek 9) strukturní grafy ostatních obcí jsou k dispozici v Přílohách 14-18. Výsledky všech obcí byly navíc shrnuty do přehledové tabulky (Tabulka 3), která byla vytvořena pomocí skriptu v Pythonu. Výpočet zahrnoval filtraci obcí, následný

výpočet průměru počtu každé kategorie osob v každé obci za sedm dní pro aktivní část dne (6:00-21:00) a noc (22:00-05:00) zvlášť ve dvou obdobích (léto a podzim 2022). Následně byl vypočítán rozdíl mezi aktivní částí dne a nocí pro každou obec, kategorii osob (rezidenti, návštěvníci, dojíždějící) a časové období (léto, podzim). Výsledkem je tabulka znázorňující rozdíl mezi dnem a nocí pro v období léta a podzimu pro každou definovanou obec.


Interpretace výsledků – Dolní Morava (návštěvnická obec)

Na základě předpokladu o turistickém charakteru obce byla Dolní Morava zařazena jako návštěvnická obec. Tento předpoklad se potvrdil, ve vizualizaci (viz Obrázek 9) je patrný výrazný podíl návštěvníků v aktivní části dne, a to jak v letním, tak podzimním období. Přes den návštěvníci jasně dominují, zatímco podíl rezidentů klesá. Tento pokles však není nutné interpretovat jako úbytek počtu rezidentů, ale spíše jako procentuální převážení návštěvníků, což je typické právě pro rekreační obce.

V podzimním období dochází k mírnému nárůstu dojíždějících, zejména ve všední dny. Tento trend může souviset se sezonními pracovními místy v oblasti cestovního ruchu, která nejsou během letních prázdnin tolik obsazována. Doplnující data ze sady A (viz Tabulka 2) naznačují, že v porovnání s létem dochází i k nárůstu podílu vyjíždějících rezidentů, pravděpodobně v souvislosti s návratem k běžnému pracovnímu a školnímu režimu.

Graf zachycuje typickou sezónní strukturu populace v obci zaměřené na turistiku, kde aktivní denní režim je tvořen především návštěvníky, zatímco v nočních hodinách převažují rezidenti. Zaznamenané rozdíly mezi létem a podzimem navíc odhalují kombinovaný režim, kde vedle turismu hraje roli i sezónní zaměstnanost a školní cyklus.

Tato zjištění korespondují s výsledky kapitol 4.2 a 4.3, kde byly identifikovány podobné vzorce mobility například v obcích Jeseník a Velké Losiny. Dolní Morava tak představuje typický příklad návštěvnické obce, u které dochází ke kombinaci vysoké denní návštěvnosti a částečné sezónnosti ve struktuře rezidentů i dojíždějících.



Obrázek 9 – Strukturální graf znázorňující podíly jednotlivých kategorií osob v Dolní Moravě v roce 2022

Tabulka 2 – Doplnující data ze sady A (vyjíždějící a nevyjíždějící) pro vybrané obce a celkový počet rezidentů

| Období | Léto 2022 | | | Podzim 2022 | | |
|------------------|---------------|-------------|------------------|---------------|-------------|------------------|
| | Nevyjíždějící | Vyjíždějící | Rezidenti celkem | Nevyjíždějící | Vyjíždějící | Rezidenti Celkem |
| Dolní Morava | 69,18 % | 30,82 % | 159 | 52,22 % | 47,78 % | 90 |
| Jeseník | 85,91 % | 14,09 % | 2 367 | 83,96 % | 16,04 % | 2 141 |
| Hranice | 88,52 % | 11,48 % | 5 037 | 84,03 % | 15,97 % | 4 642 |
| Lutín | 63,70 % | 36,30 % | 727 | 58,29 % | 41,71 % | 724 |
| Velký Týnec | 76,41 % | 23,59 % | 852 | 63,47 % | 36,53 % | 826 |
| Křelov-Břuchotín | 54,78 % | 45,22 % | 743 | 39,51 % | 60,49 % | 691 |

Výsledky strukturní analýzy ukazují, že předpokládané hypotézy o typu obce byly ve většině případů potvrzeny. V obcích s turistickým charakterem, jako je Dolní Morava nebo Jeseník, se skutečně během dne zvyšoval podíl návštěvníků a struktura populace odpovídala návštěvníckému typu. Obce jako Hranice nebo Lutín naplnily charakteristiky dojíždějících obcí – tedy s vyšším podílem dojíždějících v aktivní části dne a mírným poklesem rezidentů. Naopak obce jako Velký Týnec nebo Křelov-Břuchotín potvrdily hypotézu o rezidenční obci, zároveň po porovnání se sadou A vykazovala obec Křelov-Břuchotín vyjíždějící charakter, lze ji tedy klasifikovat jako satelitní obec s vysokou vyjížděnkou.

Z výsledků vyplývá, že kombinace datových sad B a A poskytla komplexnější pohled na mobilitu obyvatel a umožnila hlubší interpretaci. Srovnání aktivní a pasivní části dne se ukázalo jako zásadní, díky němu bylo možno odstranit zkreslení vlivem rezidentů. Tabulky s vyjíždějícími a nevyjíždějícími navíc rozšířily klasifikaci obcí a umožnily odhalit, které obce jsou vyjíždějící a které čistě rezidenční.

Celkově lze říct, že struktura populace výrazně souvisí s polohou obce, její funkcí v regionu a sezónními faktory. Zvolená metodika se ukázala jako vhodná pro rychlou identifikaci typu obce a jejího vývoje v čase. Zjištěné výsledky mohou být inspirací pro další aplikace při hodnocení funkčního charakteru území či tvorbě typologie obcí.

Tabulka 3 – Rozdíl jednotlivých kategorií osob dle vzorce počet osob ve dne – počet osob v noci, zobrazeno zvlášť pro léto a pro podzim. Nakonec závěrečné potvrzení či vyvrácení hypotézy.

| Obec | Hypotéza (typ obce) | Rozdíl rezidenti (léto, podzim %) | Rozdíl dojíždějící (léto, podzim %) | Rozdíl návštěvníci (léto, podzim %) | Potvrzení hypotézy |
|------------------------------|----------------------------|--|--|--|---|
| Dolní Morava | návštěvníká | -7,56 -13,36 | 2,16 8,24 | 5,4 5,12 | ano |
| Jeseník | návštěvníká | -13,72 -15,31 | 7,51 9,87 | 6,22 5,44 | ano, ale větší dojížd'ka |
| Hranice | dojíždějící | -13,37 -16,27 | 7,12 9,98 | 6,26 6,29 | ano |
| Lutín | dojíždějící | -14,2 -15,53 | 6,7 8,55 | 7,5 6,99 | ano |
| Velký Týnec | rezidenční/ vyjíždějící | -16,84 -17,95 | 5,82 7,79 | 11,03 10,16 | ano, rezidenční |
| Křelov- Břuchotín | rezidenční/ vyjíždějící | -13,89 -13,15 | 4,61 5,8 | 9,29 7,35 | ano, vyjíždějící |

4.5 Animace změn přítomnosti rezidentů a návštěvníků

Pro doplnění statických vizualizací a detailní ilustraci denní dynamiky v čase byly vytvořeny animované kartodiagramy zachycující změny přítomnosti osob v jednotlivých obcích v průběhu dne. Cílem bylo demonstrovat možnost využití časoprostorové vizualizace při práci s mobilními daty a ukázat, jak se mění počet rezidentů a návštěvníků v závislosti na čase, dni v týdnu a ročním období.

Byly vytvořeny dvě samostatné animace. První porovnává přítomnost rezidentů v obdobích léto 2022 a podzim 2022, druhá porovnává přítomnost návštěvníků v pandemickém období (léto 2020) a post-pandemickém období (léto 2022). Všechny animace byly vytvořeny pro každé časové období zvlášť a následně dodatečně zobrazeny vedle sebe pro porovnání dvou časových období. Vizualizace byly vytvořeny v rámci celého sledovaného období. Symboly byly znázorněny jako kruhové kartodiagramy, jejichž velikost byla hodnotově škálována podle webového nástroje, který umožňuje správně vygenerovat velikostní měřítko pro hodnotové znaky.

Příprava dat byla technicky náročná. Původní data bylo nutné převést specifického formátu časové značky, aby byla správně načtena do programu ArcGIS Pro, tento převod byl proveden v programu Excel. Každý časový interval byl reprezentován jako samostatný záznam, což při zvoleném rozsahu znamenalo až stovky záznamů pro jednu obec (např. 100 záznamů pro návštěvníky za jeden týden). To vedlo k duplicitním záznamům pro jednu obec, ale bylo to nezbytné pro správné fungování časové vizualizace v prostředí ArcGIS Pro.

Pro rezidenty byly filtrovány záznamy pouze z pracovního týdne v konkrétních časech, tedy 6:00–10:00 a 15:00–23:00, pro návštěvníky byly filtrovány záznamy za pátek až neděli v časech 8:00–20:00, vždy po hodinách.

Jedním z hlavních technických omezení byla nemožnost přidat do animace rozvržení (layout), měřítko a legendu přímo v programu ArcGIS Pro. Z toho důvodu byly tyto prvky dodatečně doplněny v externím editoru (CapCut). Snahy využít alternativní prostředí jako QGIS narážely na podobná omezení a menší kompatibilitu s větším množstvím dat. Dalším

problémem byla vizualizace katastrálních území Olomouce pomocí kartodiagramu, která se překrývala s ostatními vrstvami. Původní záměr byl zvýšit jejich čitelnost pomocí průhlednosti symbolů, ale ukázalo se, že při exportu animace dochází ke změně barev průhledných symbolů. Tento technický bug se nepodařilo vyřešit v dostupném čase, a protože by výsledek nepřinesl zásadní zlepšení s ohledem na cíle analýzy, byla průhlednost nakonec vypuštěna.

Výsledné animace slouží především jako demonstrační ukázka možného přístupu ke ztvárnění časoprostorových změn a potvrzují, že mobilní data mohou být efektivně využita i pro tvorbu dynamických kartografických výstupů. Animace jsou součástí digitálních médií.

Interpretace výsledků animací

V případě animace návštěvníků lze pozorovat typický denní cyklus – nástup pohybu od 9. hodiny ranní, kulminaci kolem 13.–14. hodiny a následný pokles směrem k večeru. Nejvyšší koncentrace návštěvníků bývá obvykle v pátek, následuje neděle a až poté sobota. Mezi jednotlivými obdobími léta 2020 a 2022 nejsou pozorovatelné jednoznačné plošné rozdíly. V některých obcích je návštěvnost vyšší během pandemického léta (např. díky rekreaci v přírodě), jinde v postpandemickém období. Celkový obraz je tedy různorodý.

Animace rezidentů ukazují, jak se jejich přítomnost mění v průběhu pracovního dne. Nejvyšší počty jsou zaznamenány ve večerních a časných ranních hodinách, což odpovídá běžnému rytmu pobytu doma. Během dopoledne a odpoledne dochází ke snížení počtu rezidentů, což reflektuje jejich dojížděku za prací či školou.

Přestože animace neodhalují zcela jednoznačné trendy nebo anomálie, velmi dobře slouží jako ukázka toho, jak lze data tohoto typu vizualizovat. Představují intuitivní nástroj pro znázornění denních a týdenních rytmů a mohou být využity k dalšímu experimentování s prezentací časoprostorových dat v interaktivní podobě.

4.6 Ukazatele mobility

4.6.1 Mobilita rezidentů a relativní bilance dojížděky

Bylo nutné rozšířit explorační analýzu o prostorovou složku v podobě mapových výstupů, pro tyto účely byly vytvořeny dva ukazatele mobility: mobilita rezidentů a identifikace dojížděky a vyjížděky. Tyto ukazatele umožňují sledovat, zda obce během běžného pracovního dne obyvatelé spíše ztrácí (převažuje vyjížděka), nebo naopak získávají (převažuje dojížděka). Zároveň umožňuje sledovat jaký je poměr mezi mobilními a setrávajícími rezidenty.

Vstupní data

Pro výpočet byly využity datové sady A a D. Nejprve pro získání počtu příjezdějících byly z dat sady D vyfiltrovány záznamy typu `typ_cesty = 'prace_skola'`. Následně byla pomocí nástroje *Summary Statistics* spočítána suma počtu cest pro každou cílovou obec a období.

Je nutné také upozornit na určitá metodická omezení spojená s agregací dat katastrálních území na úroveň obce. Vzhledem k tomu, že data ze sady A byla pro Olomouc dostupná pouze na úrovni katastrálních území, bylo nutné tato území sloučit pomocí nástroje *Dissolve*, přičemž byly spočítány souhrnné počty rezidentů, vyjíždějících a nevyjíždějících. Výsledné tabulky byly následně propojeny s dalšími daty prostřednictvím atributu `agg_id`.

Tato agregace byla provedena z důvodu zjištění nekompatibility územních jednotek Olomouce v rámci datových sad A a D, nicméně je třeba poznamenat, že metodika výpočtu

mobility není detailně popsána – konkrétně není jasné, zda se vyjížďka počítá pouze mezi katastrálními území, nebo i mezi celými obcemi. Pokud by byla vyjížďka v sadě A definována pouze mezi katastrálními území, mohlo by v případě Olomouce docházet k nadhodnocení výjezdů (např. přechod mezi katastrálními územími by byl mylně interpretován jako skutečná vyjížďka mimo obec). To by vedlo ke zkreslení výsledků.

Z těchto důvodů je třeba výsledky pro obec Olomouc interpretovat s rezervou. Obec zde byla zahrnuta spíše pro účely doplnění regionálního obrazu, nikoli jako plnohodnotný výsledek. Jedná se o metodický kompromis, kterému by se dalo předejít jedině úplným vyřazením Olomouce z analýzy. Vzhledem k významu města v regionální struktuře však bylo rozhodnuto jej ponechat alespoň v orientační podobě.

Výpočet a zpracování

Pro výpočet indikátorů bylo nutné nejdříve vypočítat průměrné hodnoty jednotlivých kategorií osob napříč všemi obdobími:

- průměr rezidentů = $\frac{(\text{rez1} + \text{rez2} + \text{rez3} + \text{rez4})}{4}$
- průměr vyjíždějících a nevyjíždějících = obdobně
- průměr příjíždějících = obdobně

Při výpočtech bylo nutné ošetřit výskyt NULL hodnot, zejména u příjíždějících ze sady D. Pokud pro obec chyběla některá hodnota, byl průměr počítán pouze z dostupných dat, přičemž NULL hodnoty byly ignorovány.

Relativní bilance dojížděky byla spočtena podle vzorce:

$$\frac{(\text{průměr příjíždějících} - \text{průměr vyjíždějících})}{\text{průměr rezidentů}}$$

Mobilita rezidentů podle vzorce:

$$\frac{(\text{průměr vyjíždějících} - \text{průměr nevyjíždějících})}{\text{průměr rezidentů}}$$

Vizualizace výsledků

Oba indikátory byly vizualizovány zvlášť pomocí kartogramu, vznikly tedy dvě mapy:

1. Dojížděka vs vyjížďka (viz Příloha 25)
2. Mobilita rezidentů (Viz Příloha 24)

Oba indikátory byly následně spojeny do jedné kombinované mapy pomocí bivariantní stupnice (viz Obrázek 10), která umožňuje zobrazit vztah mezi dvěma kvantitativními proměnnými pomocí kombinace barev. Výsledkem je mapa, která kategorizuje obce do typologií na základě vztahu mezi denním pohybem (dojížděka) a mobilitou vlastních rezidentů. Pro lepší orientaci byly pojmenovány konkrétní typy dle kombinace hodnot obou jevů.

Použité kategorie pro klasifikaci:

- vysoká mobilita (např. dopravní uzly)
- střední hodnoty (např. stabilní či kombinované obce)
- nízká mobilita (např. soběstačné statické obce)

Interpretace výsledků

Kombinovaná bivariantní mapa (viz Obrázek 10) odhaluje výrazné prostorové rozdíly v každodenní mobilitě obyvatel. Využitím dvou klíčových indikátorů bylo možné identifikovat typy obcí podle jejich funkce v rámci regionální struktury.

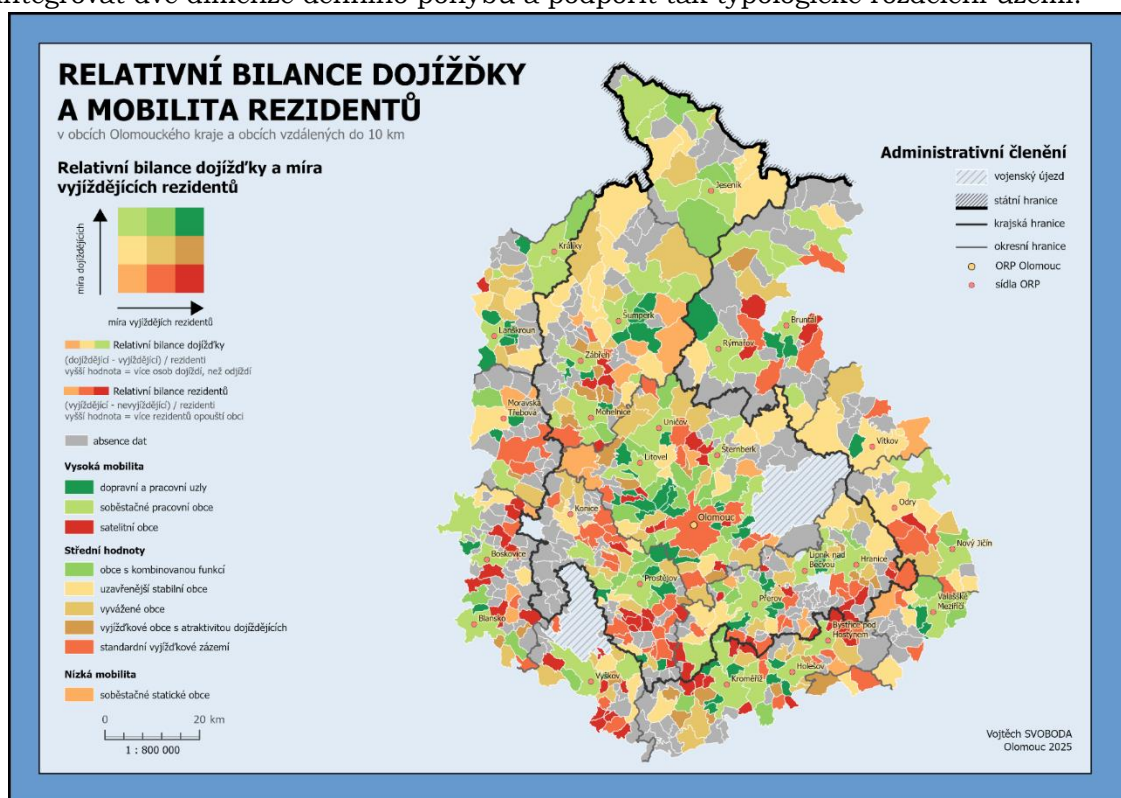
Nejvyšší mobilita (tmavě zelené odstíny) je patrná u větších dopravních a pracovních uzlů, například Prostějov, Přerov nebo Šumperk, které současně přitahují vysoký počet

dojíždějících a zároveň mají velký podíl rezidentů, kteří z nich vyjíždějí. Podobně vysokou mobilitu vykazují i satelitní obce v zázemí těchto center – například Velký Týnec či Křelov-Břuchotín, které mají silný vyjížděčkový charakter.

Naopak nízkou mobilitu (oranžové a hnědé tóny) mají obce s nízkou mírou výměny osob – tzv. soběstačné statické obce. Tyto obce mají zároveň nízký podíl dojíždějících i vyjíždějících, což může souviset s geografickou izolovaností, nedostatečnou infrastrukturou nebo menšími ekonomickými příležitostmi.

Zajímavou skupinu tvoří obce s vyváženým profilem (žluté odstíny), které kombinují vyšší počet setrvávajících rezidentů se stabilní mírou příjezdů a odjezdů. Tyto obce často vykazují kombinovanou funkci jako lokální centra.

Klasifikace a interpretace výsledků je založena na předem definovaných intervalech a vychází z typologie navržené na základě intenzity obou indikátorů. Přesto je nutné výsledky chápat jako orientační, neboť odhad dojížděčky je založen na průměrech napříč obdobími a je zatížen absencí dat u části obcí (šedé plochy). Přínosem této metody je však schopnost integrovat dvě dimenze denního pohybu a podpořit tak typologické rozdělení území.



Obrázek 10 – Relativní balance dojížděčky a mobilita rezidentů kombinováno pomocí bivariantní stupnice

5 ANALÝZA ZMĚN V DOJÍŽDĚNÍ

V rámci této části práce byla zkoumána prostorová autokorelace pomocí metody lokálního Moranova indexu s cílem identifikovat prostorové vzory v datech o dojíždějících. Tato analýza byla zaměřena na zkoumání změn mezi pandemickým a post-pandemickým obdobím v oblasti Olomouckého kraje a jeho okolí do 10 km. Pomocí této metody byly identifikovány shluky a outliery změn počtu dojíždějících mezi podzimem roku 2020 a podzimem roku 2022.

Cílem analýzy bylo nejen zjistit, jak se změnilы vzory v pohybu dojíždějících, ale také demonstrovat využití metody lokální prostorové autokorelace pro analýzu mobilních dat. Pro analýzu byla využita datová sada B. V rámci této analýzy byla zpracována výhradně kategorie dojíždějících osob.

Před samotnou prostorovou analýzou bylo nezbytné data upravit tak, aby odpovídala vybranému časovému rámci a poskytla pro každou obec jednu souhrnnou hodnotu reprezentující průměrný počet dojíždějících za vybrané období. Tento proces probíhal ve dvou krocích – nejprve v prostředí Microsoft Excel, následně v ArcGIS Pro.

Výchozí datová tabulka obsahovala hodnoty počtu dojíždějících pro každou hodinu a každý den v týdnu, přičemž každý sloupec reprezentoval konkrétní hodinu. V rámci předzpracování byly provedeny následující kroky:

- z tabulky byly odstraněny víkendové dny (sobota a neděle), aby zůstaly pouze pracovní dny (pondělí až pátek)
- z každého dne byly vybrány pouze časové úseky odpovídající typickým dojížděčkovým špičkám, tedy ranní špička (7:00–9:00) a odpolední špička (16:00–18:00)
- pro každý den tak zůstalo šest sloupců (tři hodiny ráno + tři hodiny odpoledne). Celkem tedy 30 hodnot (šest hodin × pět pracovních dní) pro každou obec a pro každé období zvlášť (rok 2020 a 2022).

Výsledné tabulky byly importovány do ArcGIS Pro a propojeny s polygonovou vrstvou obcí pomocí nástroje *Join*, přičemž spojovacím klíčem byl kód obce.

Po propojení byl pomocí nástroje *Field calculator* spočítán průměrný počet dojíždějících pro každou obec a pro každé období zvlášť. Tento průměr byl spočítán jako součet všech 30 hodnot za týden (6 hodin × 5 dní) dělený jejich počtem ($n = 30$). Následně byl pro každou obec spočítán rozdíl mezi podzimním pandemickým a post-pandemickým obdobím podle vzorce:

$$\text{absolutní změna dojíždějících} = \text{průměr (2022)} - \text{průměr (2020)}$$

Volba vstupních parametrů

Po přípravě dat a výpočtu změn mezi obdobími následovala samotná analýza pomocí nástroje *Cluster and Outlier analysis* v programu ArcGIS Pro. Tato metoda umožňuje identifikovat lokalizované shluky podobných hodnot a outliery (výrazné odchylky).

Pro analýzu byly zvoleny následující parametry:

- **conceptualization of spatial relationships:** zvolena metoda inverse distance, která váží prostorové vztahy mezi obcemi podle inverzní vzdálenosti
- **distance method:** použití euklidovské vzdálenosti pro měření vzdálenosti mezi objekty
- **distance band:** byly testovány různé hodnoty vzdálenostních pásem (30 km, 40 km, 50 km, 60 km), přičemž nejlepší výsledky přineslo nastavení s 30 km

- **standardization:** zvolena řádková standardizace (row standardization) pro optimalizaci prostorových vztahů mezi obcemi
- **number of permutations:** nastaveno na 499, což je běžná hodnota pro zajištění statistické robustnosti analýzy

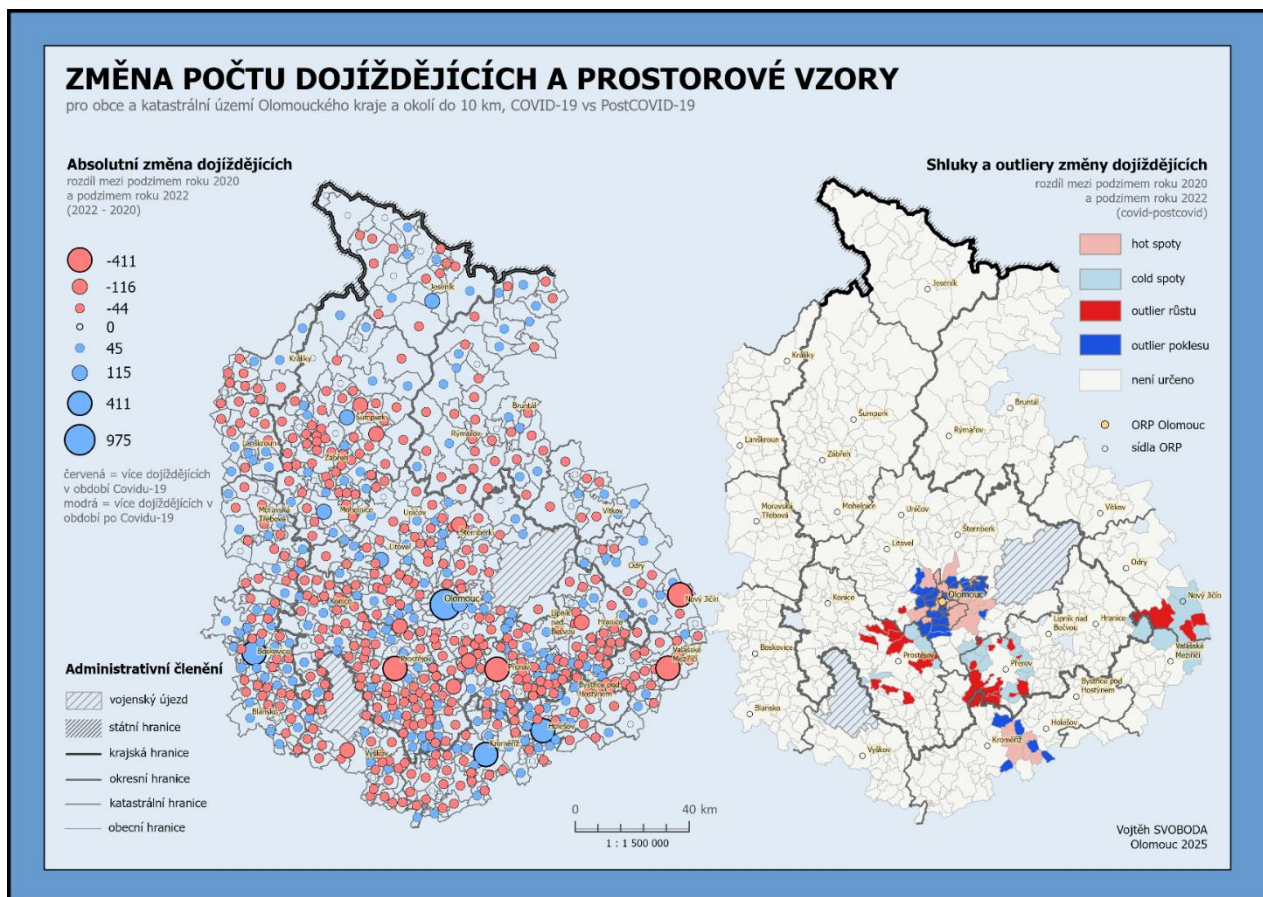
Interpretace výstupů: Změna počtu dojíždějících a prostorové vzory

Na levé straně mapového výstupu (viz Obrázek 11) je znázorněna absolutní změna počtu dojíždějících. Červené kartodiagramy indikují pokles počtu dojíždějících po pandemii (hodnota dojíždějících v roce 2022 je nižší než v roce 2020), modré naopak značí nárůst. Největší nárůst byl zaznamenán například v okolí Šumperka, Kroměříže a Holešova, což koresponduje s výsledky zmíněnými v kapitole 4.3. Naopak výrazné poklesy lze pozorovat v obcích jako Prostějov, Přerov nebo Uničov, což koresponduje s výsledky zmíněnými v kapitole 4.1.

Tato mapa ukazuje, že mobilita se po pandemii nevrátila rovnoměrně do všech oblastí. Zatímco některé obce zaznamenaly obnovení či dokonce nárůst dojíždění, jiné oblasti i nadále vykazují nižší hodnoty, což může být důsledkem trvalého přechodu na práci z domova nebo úbytku pracovních příležitostí.


Pravá část mapy ukazuje výsledek prostorové autokorelace pomocí metody lokálního Moranova Indexu. Zde jsou zvýrazněny statisticky významné prostorové vzory:

- hot spoty (světle červené) představují oblasti, kde došlo ke konzistentnímu nárůstu počtu dojíždějících i v okolních obcích. Příkladem může být zázemí Kroměříže, nebo části Olomouce
- cold spoty (světle modré) ukazují soustředěné poklesy, například v okolí Prostějova a Nového Jičína
- outliers růstu (tmavě červené) značí obce, kde došlo k výraznému nárůstu, zatímco okolí zaznamenalo pokles. Tyto výjimečné případy mohou signalizovat specifické změny v regionu, například nová pracovní místa
- outliers poklesu (tmavě modré) ukazují obce s výrazným úbytkem, přestože okolí zaznamenalo nárůst




Obrázek 11 – Změna počtu dojíždějících a prostorové vzory, podzimní pandemické vs post-pandemické období

Prostřednictvím scatter-plotu (Moranův diagram – viz Obrázek 12) byla ověřena prostorová autokorelace. Výsledky však ukázaly, že změny v počtu dojíždějících nevykazují významné prostorové vzory – $R^2 = 0$ naznačuje, že sousední obce nemají tendenci sdílet podobné změny. Většina obcí má hodnoty blízko průměru a jejich prostorové zpoždění je minimální, což ukazuje na disperzní charakter změn bez systematického shlukování.



Obrázek 12 – Scatterplot znázorňující rozložení vzniklých shluků a outlierů

Histogram (Obrázek 13) znázorňuje rozložení absolutní změny v počtu dojíždějících mezi roky 2020 a 2022. Ukazuje, že většina obcí vykazuje velmi malé změny (medián = -1), přičemž extrémní hodnoty jsou spíše výjimečné. Rozložení má mírně negativní sklon, což naznačuje, že mírný pokles dojíždění je častější než jeho nárůst, a to v souladu s výsledky z vizuální analýzy.



Obrázek 13 – Histogram ukazující absolutní změnu v počtu dojíždějících (2020 a 2022)

Celkově lze tedy říct, že změny v dojízdčkové mobilitě mezi pandemickým a post-pandemickým obdobím jsou většinou lokálního charakteru bez výrazné prostorové autokorelace. Významné nárůsty dojíždění byly zaznamenány například v Kroměříži a Holešově, zatímco Prostějov, Přerov a Uničov patří mezi oblasti s trvalejším poklesem.

6 SHLUKOVÁ ANALÝZA A TVORBA TYPOLOGIE

Příprava a zpracování dat

Pro účely této analýzy byly využity datové sady A a B. Primárně byla použita datová sada B, která poskytuje detailní časové řezky dat v hodinovém intervalu za jednotlivé dny v týdnu. Doplnkově byla využita také datová sada A, která obsahuje informace o návštěvnicích, rezidentech a jejich rozdělení na vyjíždějící a nevyjíždějící. Tato sada je založena na jiné metodice, jak již bylo zmíněno dříve. Sada A tedy nebyla využita přímo v typologii, ale sloužila pro doplňkovou validaci výsledků, zejména při určování charakteru obcí jako spíše rezidenčních, nebo spíše vyjíždějících.

Zpracování a agregace vstupních dat proběhly v prostředí Python, kde byl použit vlastní skript. Tento skript:

- načel data za všechna čtyři období
- provedl výběr hodnot podle dnů v týdnu (odděleně pracovní dny a víkendy)
- spočítal průměrné hodnoty osob v každé kategorii pro každý týdenní režim a dopočítal podíly kategorií na celkovém počtu osob

Výsledná tabulka tedy obsahovala průměrné podíly rezidentů, dojíždějících a návštěvníků zvlášť pro pracovní dny a víkendy pro každou obec a každé ze čtyř období. Tyto hodnoty sloužily jako vstupní data pro analýzy v kapitolách 6.1 a 6.2.

Po napojení výsledných dat na polygonovou vrstvu byly pomocí nástroje *Merge* propojeny katastrální území a obce do jedné polygonové vrstvy. Pro shlukovou analýzu byl využit nástroj *Multivariate clustering* v programu ArcGIS Pro, kde byly vytvořeny shluky pomocí metody K-means.


6.1 Testování různých počtů shluků a výběr optimální varianty

První testovaná varianta: 4 shluky

V rámci prvního kroku shlukové analýzy byla testována varianta se čtyřmi shluky (K=4). Na základě grafických výstupů – histogramu (viz Příloha 27) a box-plotů (viz Příloha 28) byly formulovány základní hypotézy ohledně charakteru jednotlivých skupin obcí. Výsledky naznačovaly následující typy:

- **shluk 1:** početně největší, bez výrazných extrémů – pravděpodobně běžné venkovské obce se stabilním zastoupením všech kategorií osob
- **shluk 2:** malý počet obcí s vysokým podílem návštěvníků, zejména o víkendech – odpovídá turistickým lokalitám
- **shluk 3:** vyšší podíl rezidentů, nižší podíl dojíždějících – možné rezidenční obce
- **shluk 4:** nejvyšší podíl dojíždějících, stabilní hodnoty napříč týdnem, nižší podíl rezidentů – průmyslové nebo tranzitní obce

Přestože výsledky přinesly zajímavé vzorce, rozdělení obcí do shluků nebylo zcela vyvážené. Většina obcí spadala do shluku jedna nebo tři. Navíc prostorové rozložení nenaznačovalo dostatečně jednoznačné typy. Na základě pseudo-F statistiky bylo zvažováno větší množství shluků, konkrétně K=5, které se nakonec ukázalo jako vhodnější hranice před poklesem výkonnosti (viz Obrázek 14) v kombinaci s dobrým prostorovým rozložením.



Obrázek 14 – graf znázorňující optimální počet shluků a pomocí pseudo-F statistiky

Výběr optimálního nastavení: 5 shluků

Druhá varianta analýzy byla provedena se stanoveným počtem pěti shluků ($K=5$). Shlukování opět proběhlo se stejným nastavením. Vstupními proměnnými byly průměrné podíly rezidentů, dojíždějících a návštěvníků odděleně pro pracovní dny a víkendy ve všech čtyřech časových obdobích (léto a podzim 2020, léto a podzim 2022). Celkem tedy do analýzy vstupovalo 24 proměnných. Výsledek byl vizualizován v programu ArcGIS Pro (viz Obrázek 15).

6.2 Interpretace typologie při $K=5$

Po provedení shlukové analýzy s počtem shluků $K=5$ byla provedena podrobná interpretace výstupů na základě histogramu (viz Příloha 29) a box-plotu (viz Příloha 30). Tyto vizualizace umožnily zhodnotit, jaké charakteristiky mají jednotlivé shluky a jak dobře se odlišují.

Histogram ukázal rozložení obcí mezi jednotlivé shluky. Nejvíce obcí spadalo do shluku jedna a dva, což naznačuje, že tyto dvě skupiny zahrnují běžné typy obcí s vyváženější strukturou populace. Shluk tři a zejména shluk čtyři byly výrazně méně početné, což poukazuje na specifický charakter obcí, které do těchto kategorií spadají. Box-ploty dále odhalily rozdíly v podílech jednotlivých kategorií osob – rezidentů, dojíždějících a návštěvníků mezi shluky. Na základě grafických výstupů byla provedena následující charakteristika shluků:

- **shluk 1** zahrnuje obce s výrazně vysokým podílem rezidentů a nízkým zastoupením dojíždějících a návštěvníků – jedná se pravděpodobně o stabilní rezidenční obce,

kteře mohou plnit funkci přiměstských sídel nebo venkovských oblastí s malou pracovní nabídkou

- **shluk 2** vykazuje rovněž vyšší podíl rezidentů, avšak mírně vyšší podíl dojíždějících než shluk jedna, návštěvníci jsou zastoupeni rovnoměrně – tento shluk může odpovídat přiměstským obcím, kde se kombinuje bydlení s určitou úrovní vyjížděky
- **shluk 3** má nejvyšší podíl dojíždějících a nižší podíl rezidentů a mírně vyšší podíl návštěvníků – jedná se pravděpodobně o menší pracovní centra nebo dopravní uzly, kde dochází k výrazné pracovní migraci
- **shluk 4** je specifický vysokým podílem návštěvníků, zatímco rezidenti i dojíždějící jsou zastoupeni minimálně – tento shluk jasně reprezentuje turistické a rekreační oblasti
- **shluk 5** rovněž vykazuje vyšší podíl návštěvníků, i když ne tak výrazný jako shluk čtyři. Zároveň má vyšší podíl rezidentů než shluk čtyři a podobně nízký podíl dojíždějících (může jít o obce s kombinovanou rekreační a rezidenční funkcí)

Výběr reprezentativních obcí

Aby bylo možné validovat a lépe interpretovat výsledky shlukové analýzy, byly vybrány reprezentativní obce podle předpokládané struktury obyvatel. Pro každou obec byla stanovena hypotéza o očekávaném zařazení do shluku na základě jejího obecně známého charakteru.

Pracovní a ekonomická centra (očekáváme shluk dva, nebo shluk tři)

- **Přerov** lze považovat za dopravní uzel a průmyslové centrum s větší zaměstnaností v průmyslu či logistice, díky tomu lze očekávat vyšší podíl dojíždějících za práci
- **Hranice** lze charakterizovat jako průmyslové centrum, kde sídlí významné průmyslové podniky například Cement hranice, lze opět očekávat vyšší podíl dojíždějících, ale také větší vyjížděku do okolních měst
- **Šumperk** lze charakterizovat jako regionální centrum s průmyslem a službami, jedná se o dojížděkové průmyslové centrum s větším počtem služeb
- **Mohelnice** je další město s vysokou zaměstnaností a průmyslem, sídlí zde například firma Siemens
- **Uničov** představuje průmyslově orientované město s vyšším podílem zaměstnanosti ve výrobních sektorech (např. Unex a další), proto lze očekávat zvýšený podíl dojíždějících i rezidentů, kteří za práci dojíždějí do okolních větších center

Rezidenční a dojížděková centra (lze očekávat shluk jedna, nebo dva)

- **Prostějov** je město o kterém lze říci, že má svůj vlastní pracovní trh, ale hraje zde roli silná vyjížděka do města Olomouc, proto bychom očekávali i větší rezidenční charakter a zároveň zde není tolik průmyslu jako například v Přerově či Hranicích
- **Olomouc-Nové Sady** je rezidenční oblast s vyšší dojížděkou, satelitní městečko hned vedle Olomouce – díky zmíněným tvrzením lze očekávat více vyjíždějících, tedy více rezidentů
- **Bělkovice-Laštany** jsou typickou přiměstskou obcí v zázemí Olomouce – jejich charakter odpovídá satelitnímu sídlu s vyšším podílem rezidentů, kteří pravidelně dojíždějí za práci či vzděláním do krajského města

Turistické a rekreační oblasti (lze očekávat shluk čtyři nebo pět)

- **Velké Losiny** jsou známé lázněmi, zámek a termálním parkem – díky těmto prvkům lze očekávat zvýšený podíl návštěvníků a sezonní turismus

- **Karlova Studánka** je známá horská turistická destinace, kde hodně lidí cestuje za rekreací či turistikou

Následně bylo porovnáno skutečné zařazení obce do shluku s očekáváním. Výsledky byly shrnuty v Tabulce 4.

Tabulka 4 – Validace klasifikace obcí na základě očekávaných charakteristik

| Obec | Očekávaný shluk | Skutečný Shluk | Odpovídá realitě? |
|--------------------------|-----------------|----------------|-------------------|
| Bělkovice-Laštany | 1 | 1 | ANO |
| Uničov | 2, 3 | 1 | NE |
| Přerov | 2, 3 | 1 | NE |
| Hranice | 2, 3 | 1 | NE |
| Šumperk | 2, 3 | 1 | NE |
| Mohelnice | 2, 3 | 2 | ANO |
| Velké Losiny | 4, 5 | 4 | ANO |
| Prostějov | 2, 3 | 1 | NE |
| Karlova Studánka | 4, 5 | 3 | ANO |
| Olomouc-Nové Sady | 1, 2 | 2 | ANO |

Doplňující validace pomocí podílů kategorií osob

Pro každý shluk z atributové tabulky byly zobrazeny průměrné podíly jednotlivých kategorií osob (viz Tabulka 5), stejně jako konkrétní hodnoty pro vybrané obce (viz Tabulka 6). Tyto hodnoty ukázaly, že některé obce (např. Hranice, nebo Šumperk) vykazují vyšší podíl dojíždějících, než je průměr ve shluku jedna, do kterého byly zařazeny. Zároveň ale tyto obce nevykazují dostatečně vysoké hodnoty, aby spadaly do shluku dva nebo tři, což naznačuje, že se nacházejí „na hraně“ mezi více typy. Interpretace shluku jedna byla proto rozšířena o tvrzení, že se jedná velká města s vyšší vyjížděnkou, která mohou vykazovat rezidenční charakter, například kvůli vysokému počtu nočních rezidentů.

Tabulka 5 – Složení jednotlivých shluků podle průměrných podílů kategorií osob

| Číslo shluku | Průměrný podíl rezidentů | Průměrný podíl dojíždějících | Průměrný podíl návštěvníků |
|--------------|--------------------------|------------------------------|----------------------------|
| Shluk 1 | 81,9 % | 8,2 % | 9,8 % |
| Shluk 2 | 70,9 % | 14,3 % | 14,7 % |
| Shluk 3 | 55,5 % | 23,0 % | 21,4 % |
| Shluk 4 | 53,1 % | 8,9 % | 37,9 % |
| Shluk 5 | 71,2 % | 9,5 % | 19,2 % |

Tabulka 6 – Srovnání podílů kategorií osob ve vybraných obcích

| Obec | Podíl rezidentů | Podíl dojíždějících | Podíl návštěvníků |
|-----------|-----------------|---------------------|-------------------|
| Přerov | 79,4 % | 11,4 % | 9,2 % |
| Prostějov | 81,8 % | 10,5 % | 7,7 % |
| Uničov | 77,8 % | 12,8 % | 9,4 % |
| Hranice | 73,6 % | 15,4 % | 11,0 % |
| Šumperk | 77,4 % | 13,8 % | 8,8 % |

Doplňující data – vyjíždějící a nevyjíždějící

Pro ještě hlubší analýzu charakteru některých obcí byla využita datová sada A, která umožnila rozlišit vyjíždějící a nevyjíždějící rezidenty. Tento krok sloužil zejména pro identifikaci příměstských oblastí, tzv. satelitních městeček. Z obcí zařazených do shluků jedna a dva byly vybrány příklady, které se geograficky nacházejí v okolí větších měst (např. Olomouce, Přerova, Prostějova), a pro tyto obce byly následně spočítány podíly vyjíždějících a nevyjíždějících rezidentů, v programu Excel. Nejprve bylo nutné filtrovat pouze vybrané obce, dále pak spočítat podíl vyjíždějících a nevyjíždějících pro každou z obcí. Podíl byl počítán dle vzorce:

$$\text{podíl vyjíždějících (\%)} = \frac{\text{vyjíždějící}}{\text{rezidenti}} * 100$$

$$\text{podíl nevyjíždějících (\%)} = \frac{\text{nevyjíždějící}}{\text{rezidenti}} * 100$$

Cílem této doplňující analýzy bylo ověřit, zda shluk číslo dva skutečně zahrnuje především satelitní sídla s vysokým podílem denně vyjíždějících osob, zatímco shluk jedna odpovídá spíše stabilním rezidenčním obcím s nízkou mírou vyjížděky. Výsledky byly shrnuty v Tabulce 7.

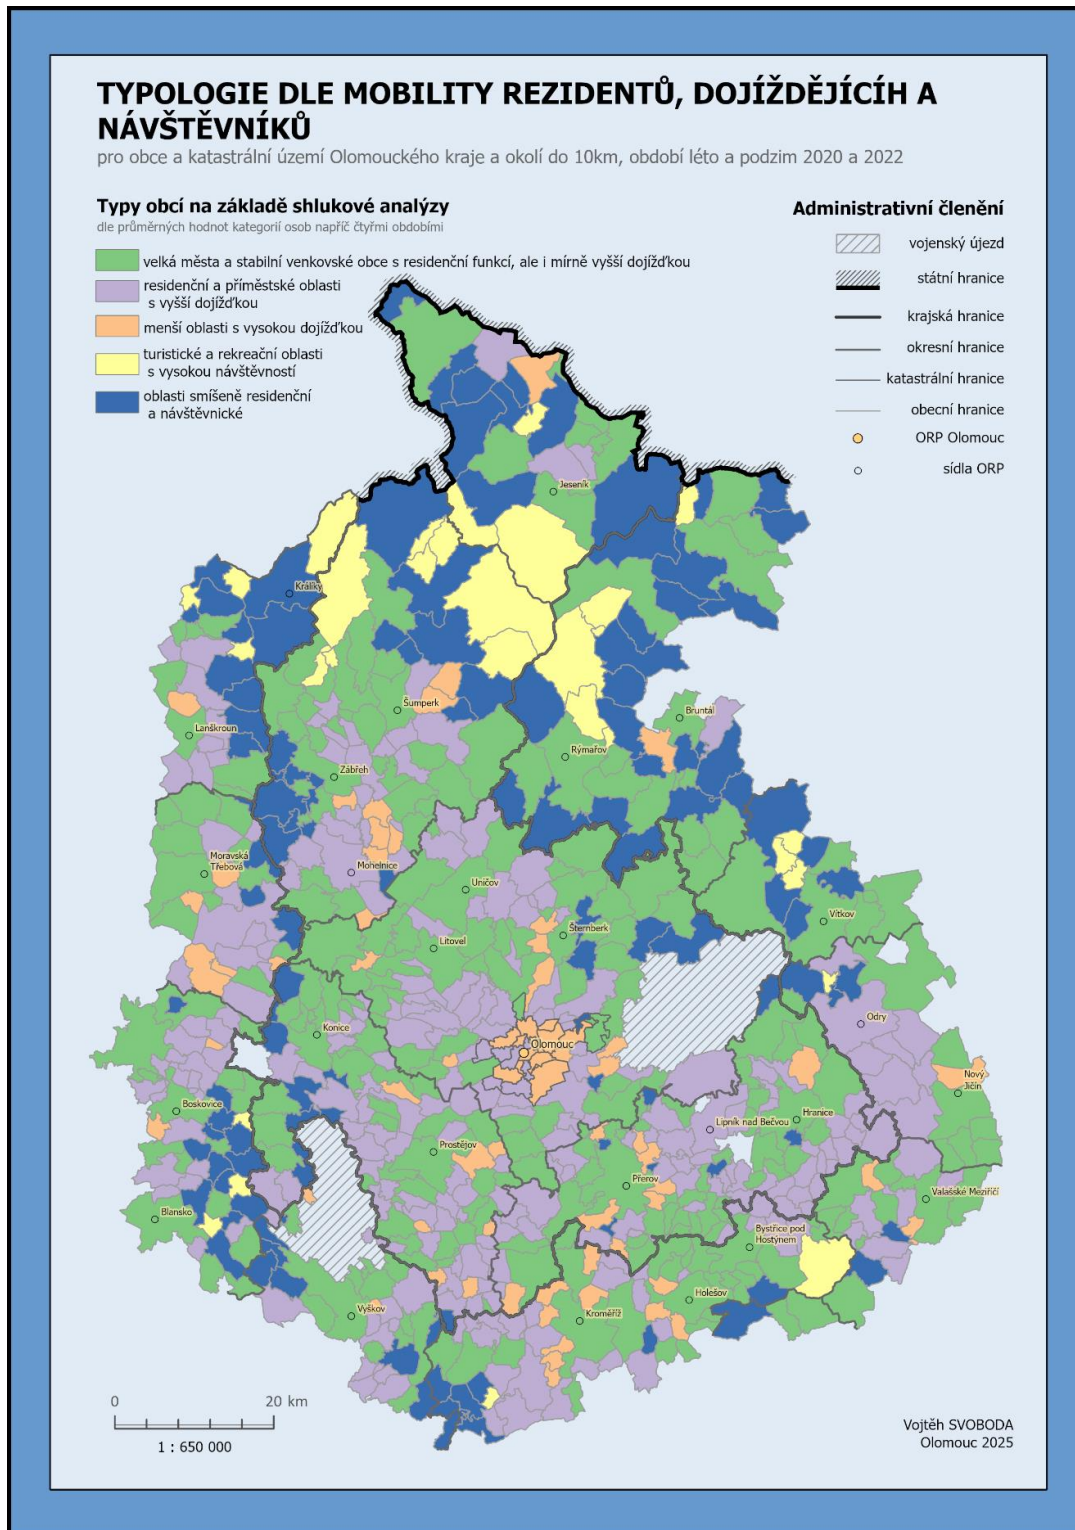
Tabulka 7 – Struktura vyjíždějících a nevyjíždějících rezidentů ve vybraných obcích (sada A)

| Obec | Shluk | Rezidenti | Vyjíždějící | Nevyjíždějící |
|-------------------------|-------|-----------|----------------|---------------|
| Křelov-Břuchotín | 2 | 733.50 | 53.17 % | 46.83 % |
| Dolany | 2 | 883.75 | 38.73 % | 61.27 % |
| Brodek u Přerova | 2 | 493.50 | 36.07 | 63.93 % |
| Výšovice | 2 | 306.50 | 35.81 % | 64.19 % |
| Bukovany | 2 | 115.25 | 52.71 % | 47.29 % |
| Hlušovice | 2 | 327,25 | 43.01 % | 56.99% |
| Beňov | 1 | 263.00 | 28.71 % | 71.29 % |
| Smržice | 1 | 584.25 | 36.79 % | 63.21 % |
| Hněvotín | 1 | 590.75 | 33.39 % | 66.61 % |
| Rokytnice | 1 | 295.75 | 38.38 % | 61.62 % |

Z výsledků je patrné, že obce zařazené do shluku dva mají ve většině případů vyšší podíl vyjíždějících rezidentů, což podporuje hypotézu, že se jedná o příměstské oblasti. Mezi typické příklady patří Křelov-Břuchotín nebo Bukovany, které leží v blízkosti Olomouce a více než polovina jejich rezidentů pravidelně vyjíždí mimo obec.

Je však třeba podotknout, že tento trend není univerzální – například obce jako Dolany nebo Brodek u Přerova zařazené do téhož shluku nevykazují až tak výrazný podíl

vyjíždějících. Proto nelze jednoznačně prohlásit, že shluk dva výhradně zahrnuje satelitní městečka, ale z výsledků lze usoudit, že právě shluk dva má k tomuto typu obcí blíže než shluk jedna. Naopak obce ve shluku jedna, jako Beňov či Hněvotín, vykazují nižší podíl vyjíždějících a vyšší podíl nevyjíždějících rezidentů, což odpovídá spíše stabilnímu residenčnímu charakteru bez silné každodenní vyjížděky. Výsledky shlukové analýzy byly vizualizovány prostřednictvím programu ArcGIS Pro (viz Obrázek 15).



Obrázek 15 – Typologie dle mobility rezidentů, dojíždějících a návštěvníků, období léto a podzim 2020 a 2022

6.3 Typologie obcí dle letní a podzimní sezóny (2022)

Původní typologie obcí byla založena na datech ze všech čtyř sledovaných období dohromady (léto a podzim 2020 a 2022), což vedlo k vysokému počtu vstupních proměnných (24). Tento přístup však komplikoval interpretaci výsledků a mohl snižovat schopnost přesně zachytit prostorové vzorce mobility. Z tohoto důvodu byla navržena nová typologie, která vychází pouze z dat za léto a podzim 2022, a to každé období zvlášť.

Příprava a zpracování dat

Data byla zpracována obdobným způsobem jako v předchozí typologii. Pomocí připraveného Python skriptu byly vypočteny průměrné hodnoty tří kategorií osob (rezidenti, návštěvníci, dojíždějící) zvlášť pro pracovní dny (po–pá) a pro víkend (so–ne). Dále byly dopočítány i absolutní počty všech osob za pracovní týden a víkend.

Celkem tak bylo pro každé období použito osm vstupních proměnných:

- průměrný podíl rezidentů (po–pá a víkend)
- průměrný podíl dojíždějících (po–pá a víkend)
- průměrný podíl návštěvníků (po–pá a víkend)
- celkový počet osob (po–pá a víkend)

Důležitým zjištěním bylo, že při vynechání proměnné znázorňující celkový počet osob docházelo ke slabé diferenciaci velkých obcí oproti menším obcím, které se pak snadno ztrácely ve velkém množství shluků. Z tohoto důvodu byly absolutní hodnoty celkového počtu osob do analýzy nakonec zařazeny, čímž se výrazně zlepšila schopnost identifikovat významnější centra.

Průběh shlukové analýzy

Shluková analýza byla provedena obdobně jako v kapitole 6.2, opět bylo zvoleno nastavení $K=5$, které se již dříve ukázalo jako vhodné a stabilní. Pro ověření robustnosti klasifikace byla testována i varianta pomocí metody K-medoids, která je odolnější vůči extrémním hodnotám – například velmi vysokým absolutním počtům osob ve velkých městech. Výsledky obou metod však byly téměř identické, a proto bylo pro zjednodušení dále pracováno pouze s výstupy K-means.

Výsledkem byly dvě samostatné typologie – pro léto a podzim 2022. Tyto výstupy byly vizualizovány ve formě map, tedy typologie pro letní období (viz Příloha 34) a typologie pro podzimní období (viz Příloha 37).

Interpretace shlukové analýzy

Na základě výsledků shlukové analýzy bylo obce možné rozdělit obce do pěti typů podle jejich funkčního charakteru. Každý shluk byl analyzován pomocí histogramu (viz Přílohy 32 a 35) a box-plotů (viz Přílohy 33 a 36).

Jednotlivé shluky byly interpretovány podle barev, které zůstaly částečně konzistentní mezi oběma obdobími. Tato barevná konzistence (např. zelená, oranžová, fialová) umožnila přesné přiřazení významu a interpretaci i při rozdílech v číslování shluků mezi sezónami.

Obecné typy obcí platné pro obě období

Některé shluky si mezi létem a podzimem zachovaly stejnou barvu, tedy i stejný charakter a lze je považovat za stabilní:

- **zelený shluk** – statické obce bez výrazné mobility a sezónnosti

Nejpočetnější skupina v obou obdobích. Box-ploty ukazují vysoký podíl rezidentů a velmi nízké hodnoty dojíždějících i návštěvníků. Tyto obce mají typický venkovský charakter bez větší variability mezi pracovními dny a víkendem.

- **oranžový shluk** – turistické (léto) a rekreační obce (podzim)

Charakteristické jsou vyšší podíly návštěvníků, velmi nízké hodnoty rezidentů i dojíždějících. Na základě box-plotů a prostorového rozložení lze předpokládat, že jde o známé turistické lokality, které si i na podzim udržují určitou atraktivitu. Název "turistické obce" byl v létě adekvátní kvůli sezónnímu vrcholu návštěvnosti. Na podzim se název mění na "rekreační obce", což lépe vystihuje mírný pokles, ale stále přetrvávající funkci rekreace.

- **fialový shluk** – velká města se statickou mobilitou

Přestože jde o méně početnou skupinu, obce v tomto shluku mají vysoké absolutní počty osob, ale relativně vyvážené podíly jednotlivých kategorií. Box-ploty naznačují stabilní strukturu bez extrémů. Název odkazuje na větší města s rozsáhlou populací a pravidelným rytmem – bez výrazného sezónního kolísání.

Proměnlivé typy obcí (změny mezi létem a podzimem)

U dvou shluků došlo mezi létem a podzimem ke změně charakteru, což poukazuje na výrazné sezónní rozdíly:

- **žlutý (léto) → zlatý (podzim)**

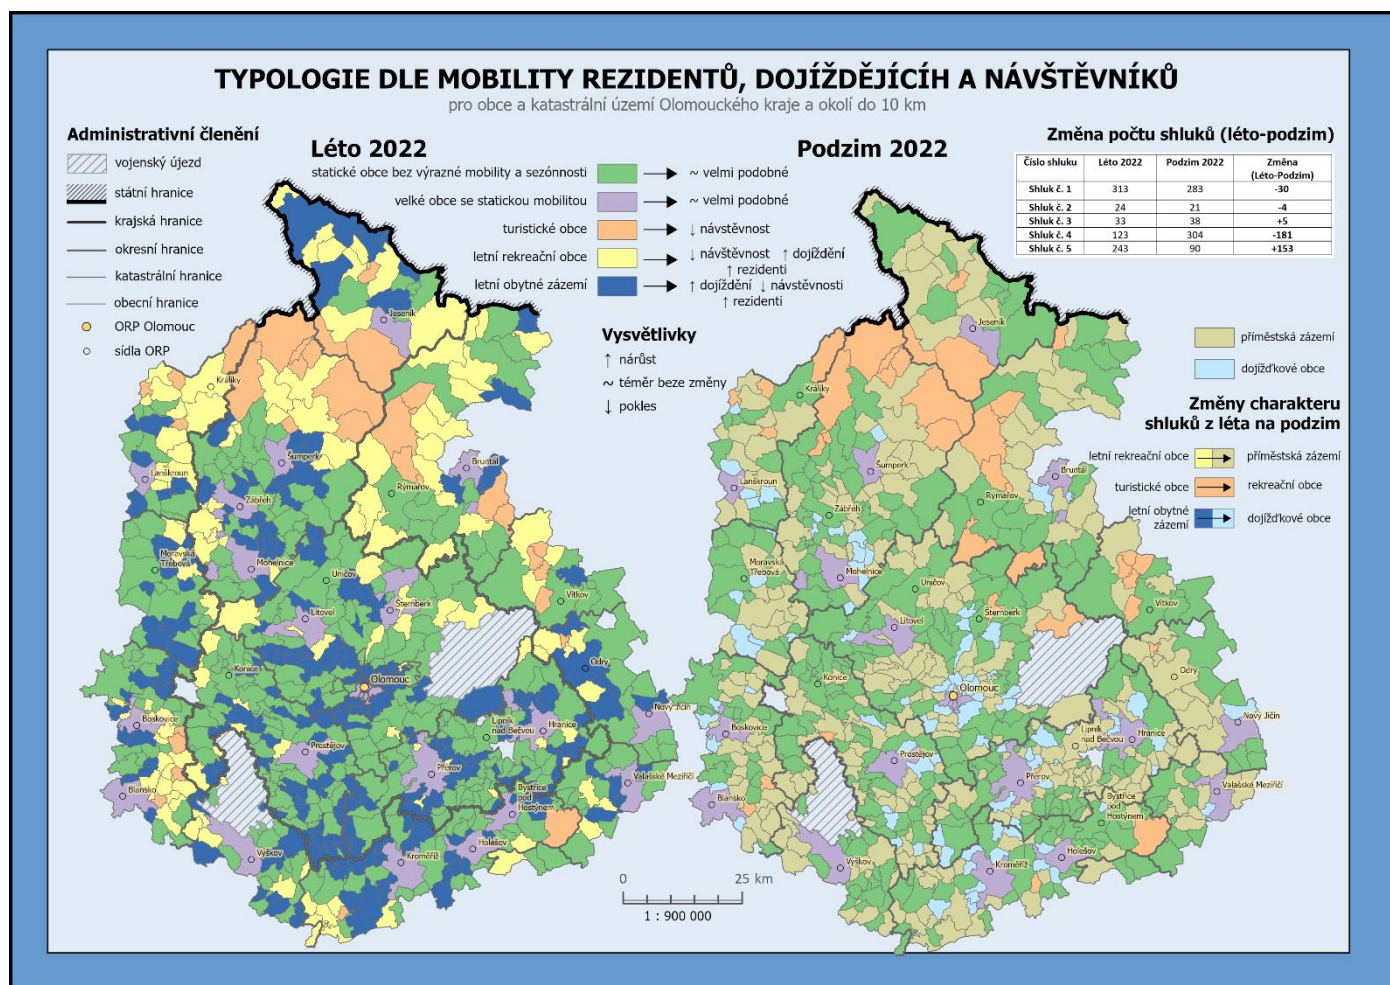
V létě byly tyto obce označeny jako "letní rekreační obce". Box-ploty ukazovaly zvýšený podíl návštěvníků během pracovního týdne, částečně i během víkendů. Obce často slouží jako chatové nebo rekreační oblasti. Na podzim dochází ke změně charakteru – ubývá návštěvníků, mírně roste podíl dojíždějících. Shluk je proto nově interpretován jako "příměstské zázemí", které na podzim více plní funkci každodenního dojížděkového prostoru. Tato změna názvu reflektuje dynamickou funkci obcí v čase.

- **tmavě modrý (léto) → světle modrý (podzim)**

Označení "letní obytné zázemí" bylo spojeno s vyššími počty osob o víkendech, zejména rezidentů, ale bez vysoké dojížděky a návštěvnosti.

Na podzim se situace mění – přibývá dojíždějících, naopak víkendová obsazenost klesá. To svědčí o návratu pravidelného pracovního režimu. Proto je tento shluk v podzimní typologii označen nově jako dojížděkové obce. Změna názvu tak zachycuje přechod od sezónního využití k běžné pracovní funkci.

Výsledné mapy typologií obou období byly sloučeny do jedné přehledové mapy umožňující jejich vzájemné porovnání. Součástí výstupu byla také tabulka zachycující změny v počtech obcí v jednotlivých shlucích mezi obdobími a zvýrazněna byla i odlišná pojmenování typů reflektující změnu jejich charakteru (viz Obrázek 16).



Obrázek 16 – Srovnání typologií obcí dle mobility rezidentů dojíždějících a návštěvníků ve dvou obdobích (léto a podzim 2022)

7 VALIDACE DAT

Za účelem ověření výpovědní hodnoty použitých dat byla provedena srovnávací analýza, nejprve s daty ze sčítání lidu, domů a bytů 2021 (SLDB 2021). Po získání další datové sady z portálu kamdojizdime.cz byl následně vypočten podíl rezidentů dle dat operátora Vodafone vůči celkovému počtu rezidentů evidovaných třemi hlavními mobilními operátory v ČR. Následně byl vytvořen regresní model, který zkoumal závislost mezi rezidenty dle Vodafone a rezidenty dle agregovaných mobilních dat všech operátorů.

7.1 Porovnání dat MPD vs SLDB 2021

Mobilní polohová data (MPD) ze sady A obsahovala počty unikátních SIM karet identifikovaných jako rezidenti v obcích během čtyř období: léto a podzim 2020 a 2022. Pro každou obec byl spočítán průměr napříč těmito obdobími. V případě obce Olomouc, kde byly hodnoty dostupné na úrovni katastrálních území, byly tyto části sloučeny do jednoho celku pomocí nástroje Dissolve v prostředí ArcGIS Pro a následně byl spočítán celkový průměr pro obec.

Tato hodnota byla následně porovnána s oficiálním údajem o počtu obyvatel v roce 2021 podle Sčítání lidu, domů a bytů (SLDB). Jelikož mobilní data pocházela pouze od jednoho operátora, byly tyto hodnoty násobeny koeficientem 4 – tedy hrubým odhadem reprezentujícím podíl daného operátora na trhu.

Výpočet byl proveden podle vzorce:

$$MPD \text{ vs SLDB (2021)} = \frac{\text{počet rezidentů dle MPD}}{\text{počet obyvatel dle SLDB 2021}} * 4$$

Výsledný relativní podíl byl vizualizován pomocí kartogramu (viz Příloha 22) v programu ArcGIS Pro, přičemž byly použity stejné intervaly a barevná škála jako v příběhové mapě (Storymap), která byla publikována autory Burian et al. (2025). Hodnoty nad 1 značily vyšší počet obyvatel podle MPD než ve SLDB, pod 1 označovaly vyšší hodnotu dle SLDB a rovno 1 indikovalo přibližně shodné hodnoty.

Z mapy byly patrné regionální rozdíly – vyšší odhady podle MPD se vyskytovaly častěji na okrajích kraje nebo v oblastech s vyšší mírou mobility. Naopak některé malé obce nebo horské oblasti vykazovaly podhodnocení, což může být způsobeno horším pokrytím signálem nebo tím, že část obyvatel nemá aktivní SIM kartu daného operátora.

Je nutné zdůraznit, že tato forma validace je pouze orientační. Koeficient 4 vychází z předpokladu rovnoměrného rozložení trhu, což nemusí být vždy splněno. Navíc výsledky mohou být ovlivněny i používáním vícenásobných SIM karet nebo specifickým chováním uživatelů.

7.2 Porovnání dat Vodafone se souhrnnými daty mobilních operátorů (Kamdojizdime.cz)

Za účelem ověření reprezentativnosti dat poskytnutých společností Vodafone byla provedena srovnávací analýza s datovou sadou FD3 z portálu kamdojizdime.cz, která zahrnuje agregovaná data všech tří hlavních mobilních operátorů působících v České republice. Obě datové sady obsahují informace o přítomnosti osob rozdělené do kategorií (rezidenti, dojíždějící, návštěvníci) ve formě časových řezů.

Jelikož se dostupná časová období v obou sadách mírně lišila, byl pro analýzu zvolen jejich nejbližší možný průnik v létě 2022:

- Vodafone (sada B): 23. 7. – 19. 8. 2022

- Kamdojizdime.cz (FD3): 18. 7. – 14. 8. 2022

Zpracování dat probíhalo v prostředí Python, kde byla nejprve provedena filtrace a prostorové sjednocení obcí podle dostupnosti dat. Následně byla obě datová schémata převedena do dlouhého formátu (long), který umožnil snadné zprůměrování hodnot za jednotlivé hodiny, dny a týdny. Pro každou obec tak vznikla jedna průměrná hodnota reprezentující počet rezidentů v průběhu celého sledovaného období. Výpočty byly provedeny jak pro celodenní intervaly, tak pro alternativní variantu založenou pouze na nočních hodinách (21:00–5:00), která mohla lépe vystihovat dlouhodobé bydliště. Jelikož se výsledky obou přístupů ukázaly jako velmi podobné, bylo rozhodnuto nadále pracovat s jednodušším celodenním průměrem.

Výsledné tabulky byly exportovány a následně připojeny k prostorové vrstvě obcí v prostředí ArcGIS Pro pomocí nástroje *Join*. Pomocí nástroje *Field Calculator* byl následně vypočten poměr počtu rezidentů evidovaných ve Vodafone datech vůči celkovému počtu rezidentů dle portálu Kamdojizdime.cz podle vztahu:

$$\text{podíl rezidentů (\%)} = \frac{\text{rezidenti dle Vodafone}}{\text{rezidenti dle Kamdojizdime.cz}} * 100$$


Tento výpočet byl vizualizován metodou kartogramu (viz Obrázek 18). Ačkoliv metodiky obou datových sad nejsou identické, sdílí několik podstatných rysů – obě pracují s časovými řezy, poskytují průměrné hodnoty přítomnosti osob v jednotlivých obcích a pokrývají stejné období. Hlavní rozdíl spočívá v tom, že Vodafone agreguje skutečné výskyty SIM karet ve čtyřech konkrétních dnech týdně, zatímco FD3 (kamdojizdime.cz) vytváří ideální průměrný týden z pohybu unikátních SIM napříč celým měsícem. Navíc FD3 aplikuje korekce reprezentativity a projekci na populaci, zatímco Vodafone využívá klasifikaci SIM pomocí kotevních bodů. Přesto se obě datové sady z hlediska výstupních hodnot i prostorového vzoru shodují natolik, že je lze považovat za dobře porovnatelné.

Validita dle regresního modelu

Pro ověření míry shody mezi oběma datovými sadami byl následně sestaven lineární regresní model (viz Obrázek 17, který pracoval se stejnými vstupními hodnotami jako předchozí metoda. Nezávislou proměnnou představoval počet rezidentů dle Vodafone, závislou proměnnou počet rezidentů dle FD3. Model dosáhl velmi silné korelace:

- $R^2 = 0,956$ – 95,6 % variability ve FD3 datech je vysvětleno hodnotami Vodafone
- koeficient 4,36 – na 1 osobu ve Vodafone datech připadá průměrně 4,36 osob ve FD3
- model byl statisticky vysoce významný ($p < 0,001$)

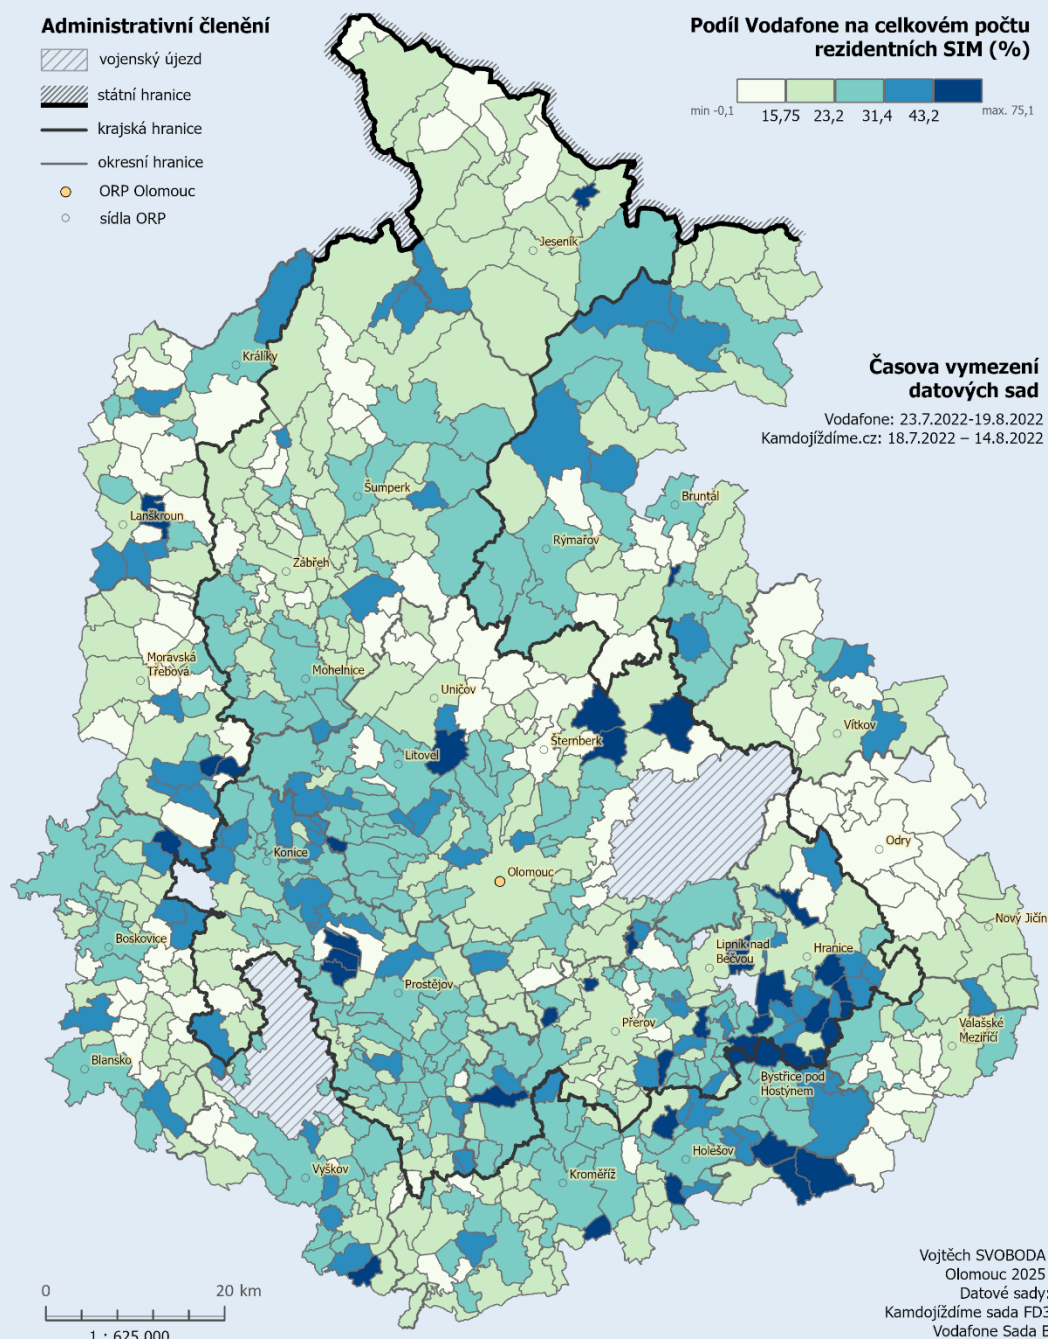
I když kartografická vizualizace ukazuje velké rozptyly, regresní analýza ukázala, že data Vodafone vykazují velmi silnou shodu s referenčními agregovanými daty všech operátorů, navzdory rozdílům v metodice. Tato srovnávací validace potvrzuje, že datová sada Vodafone lze považovat za reprezentativní zdroj pro prostorové analýzy populace v České republice.



Obrázek 17 – Lineární regrese: Vztah mezi průměrným týdenním počtem rezidentních SIM Vodafone a Kamdoojizdime (léto 2022)

POROVNÁNÍ POČTU REZIDENČNÍCH SIM VODAFONE VŮČI AGREGOVANÝM DATŮM MOBILNÍCH OPERÁTORŮ

v obcích Olomouckého kraje a do 10 km, období léto 2022



Obrázek 18 Porovnání počtu rezidenčních SIM Vodafone oproti agregovaným datům mobilních operátorů, období léto 2022

8 VÝSLEDKY

Tato kapitola shrnuje hlavní výsledky a poznatky vyplývající z jednotlivých kroků analýzy provedené v rámci kapitol 4, 5, 6 a 7. Analytický přístup byl koncipován jako ucelený příběh, který začíná explorační analýzou denní a sezónní mobility, pokračuje výpočtem indikátorů mobility, přechází k prostorové autokorelaci a vrcholí tvorbou funkční typologie obcí na základě shlukové analýzy a dále taky validací dat od Vodafone s referenčními daty. Cílem bylo nejen odpovědět na výzkumné otázky a naplnit zadání práce, ale především nabídnout ucelený pohled na prostorové a časové vzorce každodenní mobility obyvatel v Olomouckém kraji a jeho okolí.

8.1 Explorační analýza prostorové a časové mobility

V úvodní fázi analýzy (Kap. 4) byly pomocí heat-map (viz kapitola 4.2) vizualizovány denní a sezónní režimy v jednotlivých obcích. Byly identifikovány výrazné lokální rozdíly, např. zvýšená návštěvnost Jeseníku v létě 2020, která naznačuje pandemický přesun turistů do přírody. Liniové grafy (viz kapitola 4.1) umožnily porovnat denní režimy mezi lety 2020 a 2022, např. Prostějov ukázal pokles dojížděky na podzim 2022, což odporuje obecným trendům. Sloupcové grafy (viz kapitola 4.3) zdůraznily obce s nejvýraznějšími změnami, jako jsou Kroměříž, Holešov a Jeseník.

Strukturní grafy (viz kapitola 4.4) poskytly důležitý pohled na vnitřní skladbu populace, tedy podíl návštěvníků, rezidentů a dojíždějících během dne a noci. Ukázaly také, jak silně rezidenti ovlivňují strukturu ostatních kategorií a jak může být celkový obraz obce zkreslen vlivem noční převahy rezidentů. Strukturní grafy zároveň vytvořily důležitý základ pro závěrečnou typologii obcí.

Animace (viz kapitola 4.5) sloužily jako doplněk k ostatním metodám. Nabídlly možnost přímého srovnání dvou období a dynamicky ukázaly vývoj denních režimů. Jejich přínos byl především ilustrační, z analytického hlediska však nepřinášely nové informace.

Pro rozšíření kontextu zkoumaného území byly v kapitole 4.6. vytvořeny ukazatele mobility, zejména ukazatel mobility rezidentů a relativní bilance dojížděky. Tyto ukazatele umožnily lépe prozkoumat prostorové vzory jednotlivých kategorií osob a napomohly například rozlišit, které obce mají převažující vyjížděku, nebo dojížděku a jaká je mobilita rezidentů v jednotlivých obcích. Obě mapy byly nakonec shrnuty v kombinované mapě pomocí bivariantní škály, což umožnilo vytvořit „typy“ dle dojížděky a vyjížděky a charakterizovat jednotlivé obce, což tvořilo základ pro pozdější tvorbu typologie obcí (viz kapitola 6).

Explorační analýza tak přinesla široké spektrum poznatků, které byly následně využity při validaci dalších metod a potvrzení zjištěných prostorových a časových vzorců. Tato část naplnila cíle práce spojené s vizualizací časoprostorové mobility, odhalením sezónních a denních vzorců a identifikací klíčových lokalit s výraznou změnou režimu.

8.2 Zkoumání změn dojíždění pomocí prostorových analýz

V rámci kapitoly 5 byla analyzována změna počtu dojíždějících mezi dvěma obdobími pomocí metody lokální prostorové autokorelace. Byly vybrány dva klíčové časové řezy – pondělí v 8:00 a pátek v 17:00, které dobře reprezentují pracovní režimy.

Výsledkem byly mapy identifikující statisticky významné shluky (např. Prostějov jako stabilní shluk vysokých hodnot v podzimních obdobích) a odlehlé obce (např. Jeseník jako negativní outlier v létě 2020). Také byla vytvořena mapa vstupních hodnot znázorňující rozdíly v počtu dojíždějících mezi příslušnými roky. Tento výstup sloužil jako doplněk

a částečná statistická validace zjištění z explorační analýzy. Přestože samotné výsledky nepřinesly zásadní nové poznatky, analýza přispěla k rozšíření metodologického rámce a ukázala další možnosti práce s tímto typem dat.

8.3 Typologie obcí na základě shlukové analýzy

Závěrečná analýza (kap. 6) využila metodu K-means (srovnávanou s K-medoids) pro vytvoření funkční typologie obcí. Nejprve byla vytvořena komplexní typologie na základě dat za čtyři období, viz Příloha 31 (24 proměnných). Následně byla provedena samostatná typologie pouze pro léto a podzim 2022 (viz Přílohy 34 a 37), zejména kvůli jednodušší interpretaci a odstranění vlivu pandemie, který by mohl zkreslovat typickou strukturu jednotlivých obcí.

Výsledkem bylo pět typů obcí, které byly interpretovány na základě prostorového rozložení, histogramů, box-plotů a podílu kategorií osob:

- zelený shluk – statické obce s převahou rezidentů a nízkou mobilitou
- oranžový shluk – turistické (léto) a rekreační (podzim) oblasti
- fialový – velká města s vyrovnanou strukturou a stabilní mobilitou
- tmavě modrý / světle modrý shluk – sezónní obytné zázemí s víkendovým režimem, které se na podzim mění na dojížděkové oblasti
- žlutý / zlatý shluk – obce měnící funkci z letních rekreačních oblastí na příměstské zázemí

Typologie byla validována pomocí pracovních hypotéz, výběrem reprezentativních obcí a srovnáním s daty o vyjíždějících a nevyjíždějících osobách ze sady A. Výsledky byly shrnuty v přehledných tabulkách a mapách v příslušných kapitolách (6.2 a 6.3). Typologie sloužila jako finální výstup, který komplexně odráží mobilitu osob v Olomouckém kraji.

8.4 Validace dat a interpretace mobility

V kapitole 7 byla ověřena kvalita a interpretovatelnost použitých dat. V části 7.1 byl proveden odhad validity pomocí srovnání mobilních dat se Sčítáním lidu, domů a bytů (SLDB) 2021. Cílem bylo odhadnout, jak se agregovaná mobilní data shodují s oficiálními statistikami o počtu rezidentů v obcích.

Výsledky ukázaly, že hodnoty nejsou zcela totožné, přičemž někde jsou vyšší dle SLDB a někde dle MPD. Tato validace ale zůstává pouze orientační, neboť mobilní data pocházejí od jediného operátora a není znám přesný podíl tohoto poskytovatele na trhu. Pro účely vizualizace byla vytvořena doprovodná mapa znázorňující daný přepočítaný výsledek (viz Příloha 22).

V části 7.2 byla ověřena kvalita dle datové sady z portálu kamdojizdime.cz. Tato data i přes mírné odlišnosti v metodikách tvorby dat poskytla možnost hlubší validace dat, jelikož obsahovala všechny tři hlavní operátory v ČR (Vodafone, O2 a T-mobile). Pro účely porovnání byl spočítán procentuální podíl Vodafone oproti všem operátorům v jednotlivých obcích. Výsledky ukázaly velký prostorový rozptyl hodnot rezidentů a byly shrnuty do mapy (viz Obrázek 18).

V závěrečné fázi byl vytvořen regresní model (viz. Obrázek 17), který umožnil zjistit, jak dobře lze vysvětlit data z Kamdojizdime.cz pomocí dat z Vodafone. Výsledky ukázaly, že data Vodafone dobře vysvětlují agregovaná data všech operátorů. Celkově tedy bylo zjištěno, že mobilní data Vodafone jsou dobrým zdrojem dat pro vysvětlení mobility osob v Olomouckém kraji.

9 DISKUZE

Hodnocení postupů a přístupů

Úvodní fáze práce se opírala o explorační analýzu, která se ukázala jako klíčová pro prvotní porozumění datům. Využití vizualizačních metod, zejména heat-map, liniových grafů, strukturálních a sloupcových grafů umožnilo postihnout prostorové i časové aspekty mobility a odhalit specifické režimy i anomálie.

Největším přínosem explorační fáze bylo odhalení případů, které vybočují z očekávaných trendů, např. zvýšené dojíždění v Prostějově během pandemie. Tato zjištění poukázala na složitost lidské mobility a význam kontextuální interpretace dat. Explorační část zároveň ověřila vhodnost jednotlivých vizualizačních metod pro různé cíle práce.

Omezením této fáze, tedy alespoň části grafických vizualizací je ovšem nutnost výběru reprezentativních obcí. I když výběr byl podložen pracovními hypotézami a datovou strukturou, zůstává subjektivní a nelze jej snadno generalizovat na celý Olomoucký kraj. Tato slabina vedla k potřebě agregovaných přístupů v dalších analýzách. Ukazatele mobility umožnily částečně vyplnit mezeru v explorační analýze.

Strukturální grafy se ukázaly jako nejvíce přínosné, zachytily dynamiku kategorií osob ve dne i v noci a umožnily identifikaci obcí s převahou určité skupiny obyvatel. Tím připravily základ pro následnou klasifikaci obcí. Slabina těchto grafů spočívá v absenci prostorové složky, což omezilo komplexní interpretaci.

Celkově lze konstatovat, že explorace byla důležitou fází, která poskytla nejen konkrétní poznatky, ale i metodologický rámec pro další analýzy.

Validace dat a metodická úskalí

Použití dvou datových sad (A a B) přineslo nové možnosti, ale i komplikace. Zatímco sada B byla hlavním zdrojem pro většinu analýz, neobsahovala údaje o vyjíždějících a nevyláždějících rezidentech. Tyto informace byly dostupné pouze v sadě A, která navíc využívá zcela odlišnou metodiku.

Sada A je založena na počtu unikátních SIM karet. Naproti tomu sada B obsahuje hodnoty v hodinových řezech. Zatímco tedy sada A zachycuje spíše strukturu populace, sada B umožňuje analyzovat její dynamiku v čase. Tato rozdílná metodika komplikuje jejich přímé porovnání a kombinaci.

Z hlediska prostorového členění jsou obě sady kompatibilní – zahrnují obce a pro Olomouc katastrální území. Problém však nastal při snaze kombinovat tyto sady s datovou sadou D, která uvádí Olomouc jako celek (obec), zatímco sady A a B ji členily na katastrální území. Vzhledem k nejasnostem ve způsobu výpočtu (např. vyjíždka z katastrálního území vs. z celé obce) bylo rozhodnuto data zkombinovat s vědomím, že Olomouc bude označena jako metodicky problematická.

Další omezení spočívá ve skutečnosti, že data pocházejí pouze od jednoho mobilního operátora. Srovnání s výsledky SLDB sice ukázalo míru správnosti, ale kvůli absenci podílu na trhu jednotlivých operátorů není možné určit přesnou míru validity. Mapa validity tedy plní pouze orientační funkci. Naštěstí byla v závěru práce získána agregovaná data od všech mobilních operátorů, která tento problém vyřešila.

Za pozitivní aspekt lze považovat, že i přes tato omezení umožnily sady A a D vytvořit mapy relativní bilance dojížděky a mobility rezidentů, které přinesly nový a velmi cenný prostorový pohled na danou problematiku, a byly tak důležitým doplňkem výsledků ze sady B.

Tvorba typologie a její přínos

Typologie obcí představuje syntézu celé práce. První varianta s 24 proměnnými (za všechna období) byla obtížně interpretovatelná, a navíc kombinovala období s výrazně rozdílnými režimy – včetně období pandemie covidu. Bylo tedy obtížné zhodnotit, zda typologie skutečně odráží běžné chování obyvatel.

Z tohoto důvodu byla vytvořena zjednodušená verze typologie pouze pro léto a podzim 2022 s osmi proměnnými. Tento přístup umožnil lépe zachytit sezónní a funkční rozdíly mezi obcemi a vytvořit stabilnější klasifikaci.

Při výpočtu bylo nutné rozhodnout, jak data agregovat – zvolil se průměr za pracovní týden a víkend, což umožnilo vystihnout rozdíl mezi pracovní a volnočasovou mobilitou. Výpočet byl metodicky náročný, protože různá období a typy dat (sady A a B) nabízely mnoho variant přepočtu.

V souvislosti s přidáním absolutních hodnot celkového počtu osob s cílem lépe odlišit velká města od menších obcí byla testována i metoda K-medoids, která je odolnější vůči extrémním hodnotám. Výsledky se však výrazně nelišily od metody K-means, a protože ArcGIS Pro provádí interní standardizaci proměnných v rámci shlukové analýzy, bylo využito jednoduššího přístupu.

Významnou nevýhodou bylo, že typologie nemohla zahrnout proměnné ze sady A (vyjíždějící a nevyjíždějící rezidenty), protože rozdílná metodika znemožnila kombinaci se sadou B. Tím vzniklo určité omezení, např. obtížné odlišení satelitních obcí. Toto bylo částečně řešeno pomocí tabulky ze sady A pro ruční interpretaci typů.

Celkově je však typologie významným přínosem. Nabízí klasifikaci obcí podle funkčního charakteru a umožňuje snadnou interpretaci prostorových rozdílů. Zároveň také porovnání změn mezi sezónami.

Shrnutí, zhodnocení a návrhy

Bakalářská práce prokázala, že kombinací různých analytických a vizualizačních metod lze účinně zmapovat jak časové režimy mobility, tak prostorové vzorce chování obyvatel. Cílený přístup od dílčích výstupů v jednotlivých obcích po celoplošnou typologii obcí umožnil víceúrovňové porozumění regionální mobilitě.

Silnou stránkou práce bylo propojení různých datových sad a analytických metod – od vizualizací přes prostorovou statistiku až po klasifikační přístupy. Výsledky jednotlivých částí byly průběžně využívány pro validaci i interpretaci následujících analýz, čímž byl zajištěn logický tok práce. Slabší stránkou byla nutnost vyloučení některých dat z určitých analýz (např. obec Olomouc) a nemožnost plně využít všechny dostupné datové sady kvůli metodologickým rozdílům.

Metodický rámec navržený v této práci je plně přenositelný do jiných regionů nebo měřítek. Z pohledu dalšího výzkumu se nabízí několik doporučení:

- práce s daty všech operátorů – pro přesnější výsledky
- využití OD matic (sada C) - umožnilo by sledovat konkrétní směry dojížděky a vyjížděky a podpořit prostorovou interpretaci
- rozšíření typologie – zahrnutím dalších proměnných, např. vyjíždějících a nevyjíždějících rezidentů, by bylo možné lépe identifikovat satelitní nebo autonomní obce
- zohlednění demografických charakteristik – pokud by bylo možné mobilní data anonymně propojit s věkovými nebo socioekonomickými charakteristikami, analýzy by mohly mít větší vypovídající hodnotu

10 ZÁVĚR

Tato bakalářská práce se zaměřila na analýzu prostorové a časové mobility obyvatel na území Olomouckého kraje a jeho okolí, přičemž využila unikátní datovou sadu od mobilního operátora Vodafone. Cílem bylo nejen identifikovat denní a sezónní vzorce mobility, ale také ověřit kvalitu těchto dat, pomocí agregovaných dat tří hlavních operátorů v České republice z portálu kamdojizdime.cz, a vytvořit typologii obcí podle jejich funkční struktury. Práce postupovala od explorační analýzy k hlubším kvantitativním metodám a nabídla tak komplexní pohled na chování populace v prostoru a čase.

Hlavními přínosy práce je vytvoření systematického postupu, jak lze pomocí mobilních dat analyzovat každodenní mobilitu, identifikovat klíčové změny v časových režimech (např. různá struktura pracovních dní a víkendů, sezónní kolísání) a klasifikovat obce do funkčních typů podle jejich rezidenční, dojížděkové či rekreační role. Důležitou roli v této klasifikaci sehrály zejména strukturní grafy či vytvořené ukazatele mobility, které umožnily přesnější rozlišení mezi jednotlivými typy obcí a přispěly k ověření stanovených pracovních hypotéz o jejich charakteru.

Práce rovněž prokázala, že i přes určitá omezení jsou data mobilního operátora dobře interpretovatelná a mohou sloužit jako hodnotný zdroj pro analýzu časoprostorové dynamiky populace. Shluková analýza umožnila vytvořit přehlednou typologii obcí, která může být užitečná například při územním plánování.

Tato bakalářská práce tak naplnila všechny požadavky zadání – analyzovala prostorovou distribuci obyvatelstva na základě dat od mobilního operátora, navrhla a aplikovala vhodné metody pro zpracování a vizualizaci dat, identifikovala významné prostorové i časové vzorce mobility a vytvořila funkční typologii obcí, navíc výsledky shrnula v interaktivní podobě. Výsledky této práce mohou sloužit jako podklad pro další výzkumy v oblasti analýzy mobility i jako inspirace pro aplikaci mobilních dat v praxi.

POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE

AHAS, R., AASA, A., MARK, Ü., PÄÄ, T. a KULL, A., 2007. Seasonal tourism spaces in Estonia: Case study with mobile positioning data. *Tourism Management*, 28(3), s. 898–910. ISSN 0261-5177. DOI: <https://doi.org/10.1016/j.tourman.2006.05.010>

ANSELIN, L., 1995. Local indicators of spatial association—LISA. *Geographical Analysis*, 27(2), s. 93–115. ISSN 0016-7363.

BARTOLIK, M., 2023. Wi-Fi Locationing Components Overcome GNSS, Cellular Gaps for Positioning Applications. *Digi-Key Electronics* [online]. [cit. 2025-02-12]. Dostupné z: <https://www.digikey.cz/en/articles/wi-fi-locationing-components-overcome-gnss-cellular-gaps-for-positioning-applications>

Behrens, J. T. (1997). Principles and procedures of exploratory data analysis. *Psychological Methods*, 2(2), 131–160. DOI: <https://doi.org/10.1037/1082-989X.2.2.131>

Burian, J., Pászto, V., Macků, K., & Pavlík, L. (2021): Využití personalizovaných dat Google Location pro analýzu změn chování v průběhu pandemie COVID-19. *EMI*, 13(2), 1717

Center for Systems Science and Engineering (CSSE) at Johns Hopkins University. COVID-19 Dashboard [online]. [cit. 2025-05-06]. Dostupné z: <https://coronavirus.jhu.edu/map.html>

CRISAN, A., 2022. The Importance of Data Visualization in Combating a Pandemic. *American Journal of Public Health*, 112(6), s. 893–895. DOI: <https://doi.org/10.2105/AJPH.2022.306857>

ESRI. Vodafone & Mobility in Czechia. *ArcGIS StoryMaps* [online]. [cit. 2025-05-06]. Dostupné z: <https://storymaps.arcgis.com/stories/a1c5a1328e4846679583484409895137>

EVERITT, B. S., LANDAU, S., LEESE, M. a STAHL, D., 2011. *Cluster Analysis*. 5. vyd. Chichester: Wiley. ISBN 978-0470749913.

GEARY, R. C., 1954. The contiguity ratio and statistical mapping. *The Incorporated Statistician*, 5(3), s. 115–146. ISSN 1466-9404.

GETIS, A. a ORD, J. K., 1992. *The analysis of spatial association by use of distance statistics*. *Geographical Analysis*, 24(3), s. 189–206. ISSN 0016-7363. DOI: <https://doi.org/10.1111/j.1538-4632.1992.tb00261.x>

HAMPL, M., 2007. Regionální diferenciace současného socioekonomického vývoje v České republice. *Sociologický časopis / Czech Sociological Review*, 43(5), s. 889–910. ISSN 0038-0288. Dostupné z: <http://hdl.handle.net/20.500.11956/160679>

HOAGLIN, D. C., MOSTELLER, F. a TUKEY, J. W. (eds.), 1983. *Understanding Robust and Exploratory Data Analysis*. New York: Wiley. ISBN 978-0-471-09777-8.

HUNTER, John D., 2007. Matplotlib: A 2D Graphics Environment. *Computing in Science & Engineering*, 9(3), s. 90–95. DOI: <https://doi.org/10.1109/MCSE.2007.55>

JAIN, A. K., MURTY, M. N. a FLYNN, P. J., 1999. Data clustering: A review. *ACM Computing Surveys*, 31(3), s. 264–323. DOI: <https://doi.org/10.1145/331499.331504>

KAUFMAN, L. a ROUSSEEUW, P. J., 2005. *Finding Groups in Data: An Introduction to Cluster Analysis*. Hoboken: Wiley. ISBN 978-0471735786.

KÄHRIK, A., NOVÁK, J., TEMELOVÁ, J., KADARIK, K. a TAMMARU, T., 2015. Patterns and Drivers of Inner City Social Differentiation in Prague and Tallinn. *Geografie*, 120(2), s. 275–295. ISSN 1212-0014. DOI: <https://doi.org/10.37040/geografie2015120020275>

KOTVA, P., 2017. *Lokalizace a navigace uvnitř budov*. Bakalářská práce. Plzeň: Západočeská univerzita v Plzni, Fakulta aplikovaných věd.

LOUAIL, T., LENORMAND, M., PICORNELL, M., et al., 2014. From Mobile Phone Data to the Spatial Structure of Cities. *Scientific Reports*, 4, 5276. ISSN 2045-2322. DOI: <https://doi.org/10.1038/srep05276>

MACQUEEN, J., 1967. Some methods for classification and analysis of multivariate observations. In: *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*. Vol. 1. Berkeley: University of California Press, s. 281–297.

MASHIMA, D., KOBOUROV, S. G. a HU, Y., 2011. Visualizing dynamic data with maps. *Proceedings of the IEEE Pacific Visualization Symposium*, s. 193–200. DOI: <https://doi.org/10.1109/PACIFICVIS.2011.5742385>

McKINNEY, Wes. *pandas: Powerful Python data analysis toolkit* [online]. Version 2.x, [cit. 2025-05-06]. Dostupné z: <https://pandas.pydata.org/>

MORAN, P. A. P., 1950. *Notes on continuous stochastic phenomena*. *Biometrika*, **37**(1–2), s. 17–23. ISSN 0006-3444. DOI: <https://doi.org/10.1093/biomet/37.1-2.17>

NOVÁK, J., 2010. *Lokalizační data mobilních telefonů: možnosti využití v geografickém výzkumu*. Disertační práce. Praha: Univerzita Karlova v Praze, Přírodovědecká fakulta.

NOVÁK, J. a TEMELOVÁ, J., 2012. Každodenní život a prostorová mobilita mladých Pražanů: pilotní studie využití lokalizačních dat mobilních telefonů. *Sociologický časopis / Czech Sociological Review*, 48(5), s. 911–938. ISSN 0038-0288. Dostupné z: <https://sreview.soc.cas.cz/pdfs/csr/2012/05/05.pdf>

OLIVER, N., LEPRI, B., STERLY, H., et al., 2020. Mobile Phone Data for Informing Public

Health Actions Across the COVID-19 Pandemic Lifecycle. *Science Advances*, 6(23), eabc0764. ISSN 2375-2548. DOI: <https://doi.org/10.1126/sciadv.abc0764>

POSPÍŠILOVÁ, L. a NOVÁK, J., 2016. Mobile phone location data: new challenges for geodemographic research. *Demografie*, 58(4), s. 320–337. ISSN 0011-8265. Dostupné z: <https://www.researchgate.net/publication/316557616>

RADIAT, s.r.o. Diagram | Radiat.cz [online]. [cit. 2025-05-06]. Dostupné z: <https://radiat.cz/diagram/>

SEABOLD, Skipper a PERKTOLD, Josef, 2010. Statsmodels: Econometric and Statistical Modeling with Python. *Proceedings of the 9th Python in Science Conference*, s. 57–61. Dostupné z: <https://www.statsmodels.org/>

SEVTSUK, A. a RATTI, C., 2010. Does urban mobility have a daily routine? Learning from the aggregate data of mobile networks. *Journal of Urban Technology*, 17(1), s. 41–60. ISSN 1063-0732. DOI: <https://doi.org/10.1080/10630731003597322>

TIZZONI, M., BAJARDI, P., DECUYPER, A., et al., 2014. On the use of human mobility proxies for modeling epidemics. *PLoS Computational Biology*, 10(7), e1003716. ISSN 1553-7358. DOI: <https://doi.org/10.1371/journal.pcbi.1003716>

TRASARTI, R., OLTEANU-RAIMOND, A.-M., NANNI, M., et al., 2015. Discovering urban and country dynamics from mobile phone data with spatial correlation patterns. *Telecommunications Policy*, 39(3–4), s. 347–362. ISSN 0308-5961. DOI: <https://doi.org/10.1016/j.telpol.2013.12.002>

TUKEY, J. W., 1977. *Exploratory Data Analysis*. Reading (MA): Addison-Wesley. ISBN 978-0-201-07616-5.

VANHOOF, M., REIS, F., PLOETZ, T. a SMOREDA, Z., 2018. Assessing the quality of home detection from mobile phone data for official statistics. *Journal of Official Statistics*, 34(4), s. 935–960. ISSN 2001-7367. DOI: <https://doi.org/10.2478/jos-2018-0046>

VANDERPLAS, Jake, 2016. *Python Data Science Handbook: Essential Tools for Working with Data*. O'Reilly Media. ISBN 978-1491912058. Online verze dostupná z: <https://jakevdp.github.io/PythonDataScienceHandbook/>

WASKOM, Michael L., 2021. seaborn: statistical data visualization. *Journal of Open Source Software*, 6(60), 3021. DOI: <https://doi.org/10.21105/joss.03021>

WEI, B., SU, G. a LIU, F., 2023. Dynamic Assessment of Spatiotemporal Population Distribution Based on Mobile Phone Data: A Case Study in Xining City, China. *International Journal of Disaster Risk Science*, 14(4), s. 649–665. DOI: <https://doi.org/10.1007/s13753-023-00480-3>

PŘÍLOHY

SEZNAM PŘÍLOH

Vázané přílohy


- | | |
|------------|---|
| Příloha 1 | Srovnávací heat-mapy: Počet návštěvníků pro obec Jeseník, období léto 2020 vs 2022, výčet hodnot z dat |
| Příloha 2 | Srovnávací heat-mapy: Počet dojíždějících pro obec Prostějov, období léto 2020 vs 2022, výčet hodnot z dat |
| Příloha 3 | Srovnávací heat-mapy: Počet návštěvníků pro obec Velké Losiny, období léto 2020 vs 2022, výčet hodnot z dat |
| Příloha 4 | Heat-mapa: Relativní změny rezidentů v obci Šumperk, podzim oproti létu v roce 2022 |
| Příloha 5 | Liniový graf: Denní dynamika návštěvníků v obci Olomouc, všechna dostupná období |
| Příloha 6 | Liniový graf: Denní dynamika rezidentů v obci Olomouc, všechna dostupná období |
| Příloha 7 | Liniový graf: Denní dynamika dojíždějících v obci Prostějov, všechna dostupná období |
| Příloha 8 | Sloupcový graf: Obce s největším průměrným nárůstem dojíždějících na podzim 2022 v porovnání s podzimem 2020 |
| Příloha 9 | Sloupcový graf: Průměrný počet dojíždějících ve vybraných obcích (pouze pracovní týden) za všechna dostupná období |
| Příloha 10 | Sloupcový graf: Průměrný počet návštěvníků ve vybraných obcích (pouze víkend) za všechna dostupná období |
| Příloha 11 | Sloupcový graf pro obec Dolní Morava: Rozdíl v kategoriích osob mezi celodenním průměrem (00-23:59) a aktivní částí dne (6:00-21:00) v období léta 2022 |
| Příloha 12 | Sloupcový graf pro obec Dolní Morava: Rozdíl v kategoriích osob mezi celodenním průměrem (00- 23:59) a aktivní částí dne (6:00-21:00) v období podzimu 2022 |
| Příloha 13 | Strukturní graf pro obec Dolní Morava: Srovnání den vs noc a podzim vs léto (rok 2022) |
| Příloha 14 | Strukturní graf pro obec Hranice: Srovnání den vs noc a podzim vs léto (rok 2022) |
| Příloha 15 | Strukturní graf pro obec Jeseník: Srovnání den vs noc a podzim vs léto (rok 2022) |
| Příloha 16 | Strukturní graf pro obec Křelov-Břuchotín: Srovnání den vs noc a podzim vs léto (rok 2022) |
| Příloha 17 | Strukturní graf pro obec Lutín: Srovnání den vs noc a podzim vs léto (rok 2022) |
| Příloha 18 | Strukturní graf pro obec Velký Týnec: Srovnání den vs noc a podzim vs léto (rok 2022) |
| Příloha 19 | Změna dojíždění mezi obdobími COVID-19 a PostCOVID-19: Vizualizace v stupních dat do analýzy lokální prostorové autokorelace |

| | |
|------------|---|
| Příloha 20 | Prostorové změny dojíždění mezi obdobími COVID-19 a PostCOVID-19: Metoda lokální prostorové autokorelace |
| Příloha 21 | Vizualizace vstupních a výstupních dat: Změna dojíždějících a prostorové vzory |
| Příloha 22 | Validace dat: Srovnání počtu rezidentů dle mobilních polohových dat Vodafone, oproti datům ze sčítání lidu, domů a bytů v roce 2021 |
| Příloha 23 | Validace dat: Porovnání počtu rezidentních SIM Vodafone vůči agregovaným datům mobilních operátorů ze serveru kamdojizdime.cz |
| Příloha 24 | Ukazatel mobility: Mobilita rezidentů |
| Příloha 25 | Ukazatel mobility: Porovnání dojíždědky a vyjíždědky |
| Příloha 26 | Kombinace ukazatelů mobility: Relativní bilance dojíždědky a mobilita rezidentů |
| Příloha 27 | Sloupcový graf znázorňující počet obcí v jednotlivých shlucích, všechna dostupná období, K=4 |
| Příloha 28 | Box-plot znázorňující rozdělení vstupních hodnot dle shlukové analýzy, všechna dostupná období, K=4 |
| Příloha 29 | Sloupcový graf znázorňující počet obcí v jednotlivých shlucích, všechna dostupná období, K=5 |
| Příloha 30 | Box-plot znázorňující rozdělení vstupních hodnot dle shlukové analýzy, všechna dostupná období, K=5 |
| Příloha 31 | Typologie dle mobility rezidentů, dojíždějících a návštěvníků, období léto a podzim 2020 a 2022 |
| Příloha 32 | Sloupcový graf znázorňující počet obcí v jednotlivých shlucích, léto 2022, K=5 |
| Příloha 33 | Box-plot znázorňující rozdělení vstupních hodnot dle shlukové analýzy, léto 2022, K=5 |
| Příloha 34 | Typologie dle mobility rezidentů, dojíždějících a návštěvníků v období léta 2022 |
| Příloha 35 | Sloupcový graf znázorňující počet obcí v jednotlivých shlucích, podzim 2022, K=5 |
| Příloha 36 | Box-plot znázorňující rozdělení vstupních hodnot dle shlukové analýzy, podzim 2022, K=5 |
| Příloha 37 | Typologie dle mobility rezidentů, dojíždějících a návštěvníků v období podzimu 2022 |
| Příloha 38 | Srovnávací mapa typologie rezidentů, dojíždějících a návštěvníků pro podzim a léto 2022 |


Volné přílohy

| | |
|------------|--------|
| Příloha 39 | Poster |
|------------|--------|

**PRŮMĚRNÝ POČET NÁVŠTĚVNÍKŮ PRO OBEC JESENÍK
V období od 01.08.2020 do 28.08.2020 (COVID-19)**




**PRŮMĚRNÝ POČET NÁVŠTĚVNÍKŮ PRO OBEC JESENÍK
V období od 23.07.2022 do 19.08.2022 (PostCOVID-19)**

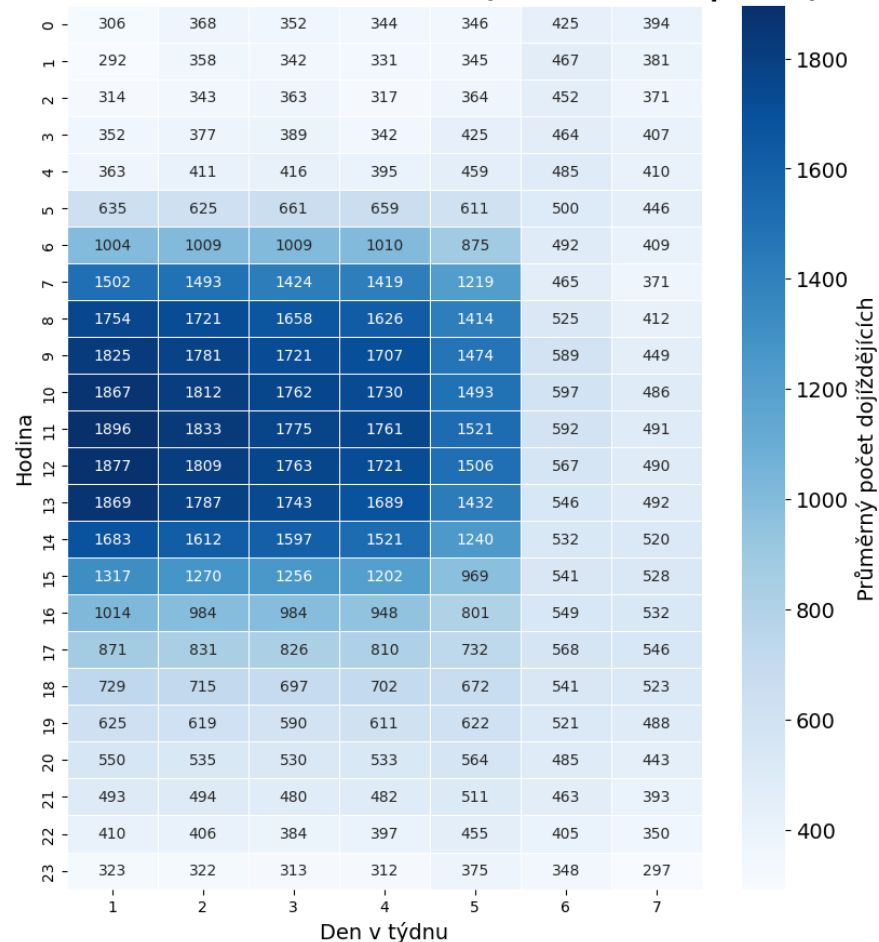


Příloha 1 Srovnávací heat-mapy: Počet návštěvníků pro obec Jeseník, období léto 2020 vs 2022, výčet hodnot z dat


**PRŮMĚRNÝ POČET DOJÍŽDĚJÍCÍCH PRO OBEC PROSTĚJOV
v období od 23.07.2022 do 19.08.2022 (PostCOVID-19 - léto)**




**PRŮMĚRNÝ POČET DOJÍŽDĚJÍCÍCH PRO OBEC PROSTĚJOV
V období od 10.10.2022 do 06.11.2022 (PostCOVID-19 - podzim)**




PRŮMĚRNÝ POČET NÁVŠTĚVNÍKŮ PRO OBEC VELKÉ LOSINY
V období od 23.07.2022 do 19.08.2022 (PostCOVID-19 - léto)



PRŮMĚRNÝ POČET NÁVŠTĚVNÍKŮ PRO OBEC VELKÉ LOSINY
V období od 10.10.2022 do 06.11.2022 (PostCOVID-19 - podzim)




Příloha 3 Srovnávací heat-mapy: Počet návštěvníků pro obec Velké Losiny, období léto 2020 vs 2022, výčet hodnot z dat



Příloha 4 Heat-mapa: Relativní změny rezidentů v obci Šumperk, podzim oproti létu v roce 2022


DENNÍ DYNAMIKA NÁVŠTĚVNÍKŮ V OLOMOUCI



Príloha 5 Liniový graf: Denní dynamika návštěvníků v obci Olomouc, všechna dostupná období


DENNÍ DYNAMIKA REZIDENTŮ V OLOMOUCI

Agregováno přes všechna katastrální území Olomouce, průměrný počet rezidentů za celý týden pro každou hodinu dne




Příloha 6 Liniový graf: Denní dynamika rezidentů v obci Olomouc, všechna dostupná období


DENNÍ DYNAMIKA DOJÍŽDĚJÍCÍCH VE MĚSTĚ PROSTĚJOV




Příloha 7 Liniový graf: Denní dynamika dojíždějících v obci Prostějov, všechna dostupná období



Příloha 8 Sloupcový graf: Obce s největším průměrným nárůstem dojíždějících na podzim 2022 v porovnání s podzimem 2020




Příloha 9 Sloupkový graf: Průměrný počet dojíždějících ve vybraných obcích (pouze pracovní týden) za všechna dostupná období




Příloha 10 Sloupcový graf: Průměrný počet návštěvníků ve vybraných obcích (pouze víkend) za všechna dostupná období

PROCENTUÁLNÍ ROZDÍL V KATEGORIÍCH OSOB - DOLNÍ MORAVA (Léto 2022)




Príloha 11 Sloupový graf pro obec Dolní Morava: Rozdíl v kategoriích osob mezi celodenním průměrem (00-23:59) a aktivní částí dne (6:00-21:00) v období léta 2022


PROCENTUÁLNÍ ROZDÍL V KATEGORIÍCH OSOB - DOLNÍ MORAVA (Podzim 2022)




Příloha 12 Sloupcový graf pro obec Dolní Morava: Rozdíl v kategoriích osob mezi celodenním průměrem (00-23:59) a aktivní částí dne (6:00-21:00) v období podzimu 2022




Príloha 13 Strukturní graf pro obec Dolní Morava: Srovnání den vs noc a podzim vs léto (rok 2022)




Příloha 14 Strukturní graf pro obec Hranice: Srovnání den vs noc a podzim vs léto (rok 2022)




Příloha 15 Strukturní graf pro obec Jeseník: Srovnání den vs noc a podzim vs léto (rok 2022)



Příloha 16 Strukturní graf pro obec Křelov-Břuchotín: Srovnání den vs noc a podzim vs léto (rok 2022)



Příloha 17 Strukturní graf pro obec Lutín: Srovnání den vs noc a podzim vs léto (rok 2022)




Příloha 18 Strukturní graf pro obec Velký Týnec: Srovnání den vs noc a podzim vs léto (rok 2022)

ZMĚNA DOJÍŽDĚNÍ MEZI OBDOBÍMI COVID-19 A POSTCOVID-19

(vstupní hodnoty do analýzy lokální prostorové autokorelace)
pro obce Olomouckého kraje a okolí do 10 km, podzim 2020 a 2022

Absolutní změna dojíždějících

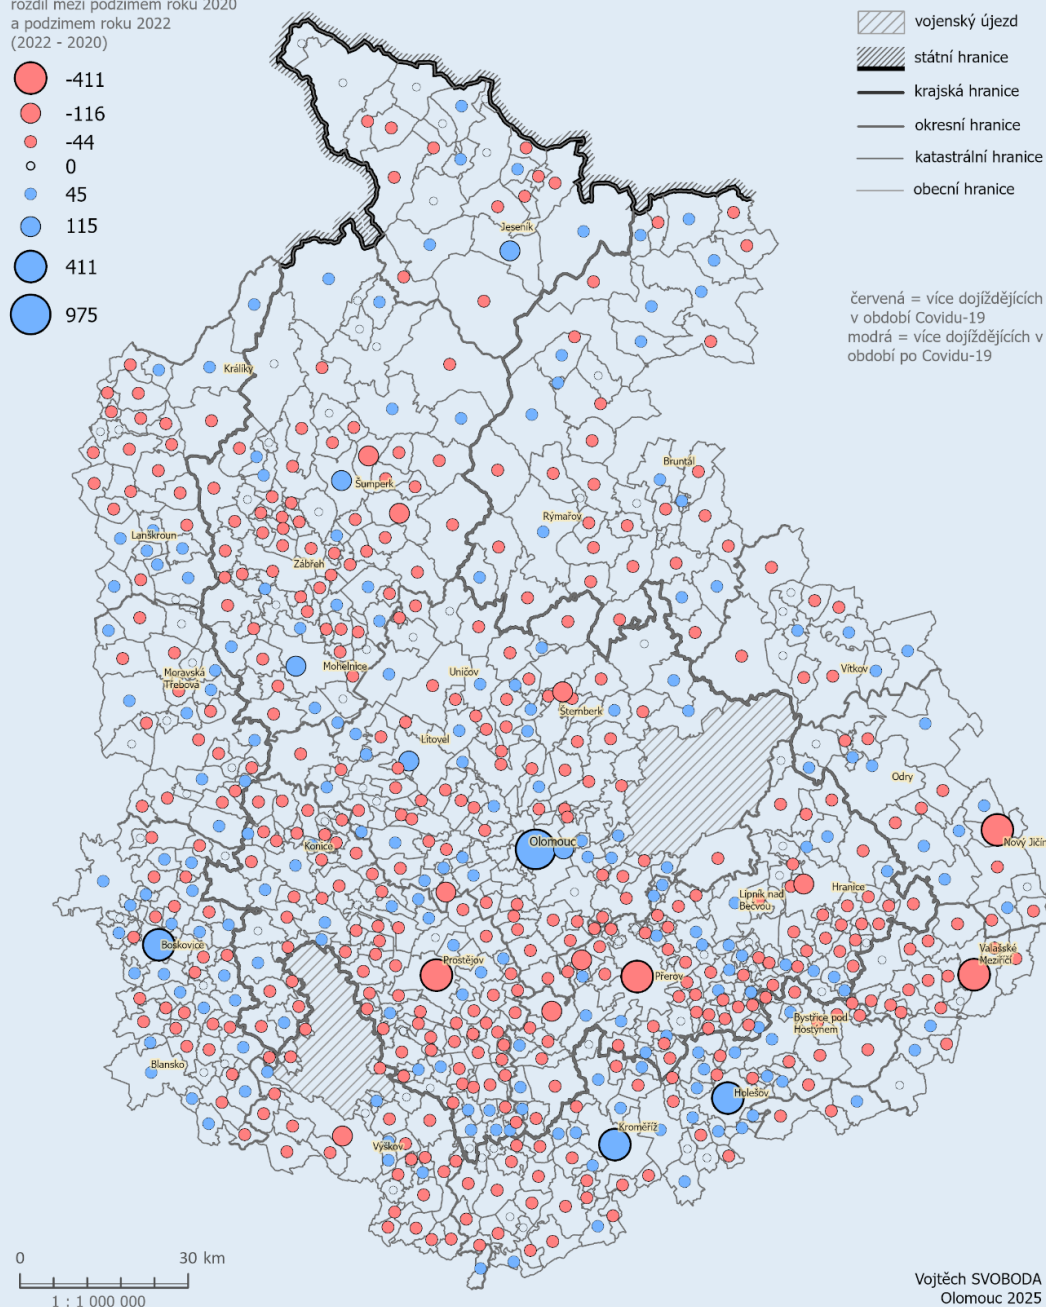
rozdíl mezi podzimem roku 2020
a podzimem roku 2022
(2022 - 2020)



Administrativní členění



červená = více dojíždějících
v období Covidu-19
modrá = více dojíždějících v
období po Covidu-19



Príloha 19 Změna dojíždění mezi obdobími COVID-19 a PostCOVID-19: Vizualizace vstupních dat
do analýzy lokální prostorové autokorelace

PROSTOROVÉ VZORY ZMĚNY DOJÍŽDĚNÍ MEZI OBDOBÍMI COVID-19 A POSTCOVID-19

pomocí metody lokální prostorové autokorelace

pro obce a katastrální území Olomouckého kraje a okolí do 10 km, podzim 2020 a 2022

Shluky a outliery změny dojíždění

Porovnání dojíždění v postcovidovém období oproti covidovému na základě rozdílu dojíždějících

Vysvětlivky

Hot spoty = Obce, kde dojíždění výrazně vzrostlo v postcovidovém období oproti covidovému a zároveň jejich okolí vykazuje podobný trend.

Cold Spoty = Obce, kde dojíždění výrazně pokleslo v postcovidovém období oproti covidovému a jejich okolí se chová podobně.

Outlier růstu = Obec, kde dojíždění v postcovidovém období vzrostlo výrazně více než v okolních obcích, které spíše zaznamenaly pokles nebo menší změnu.

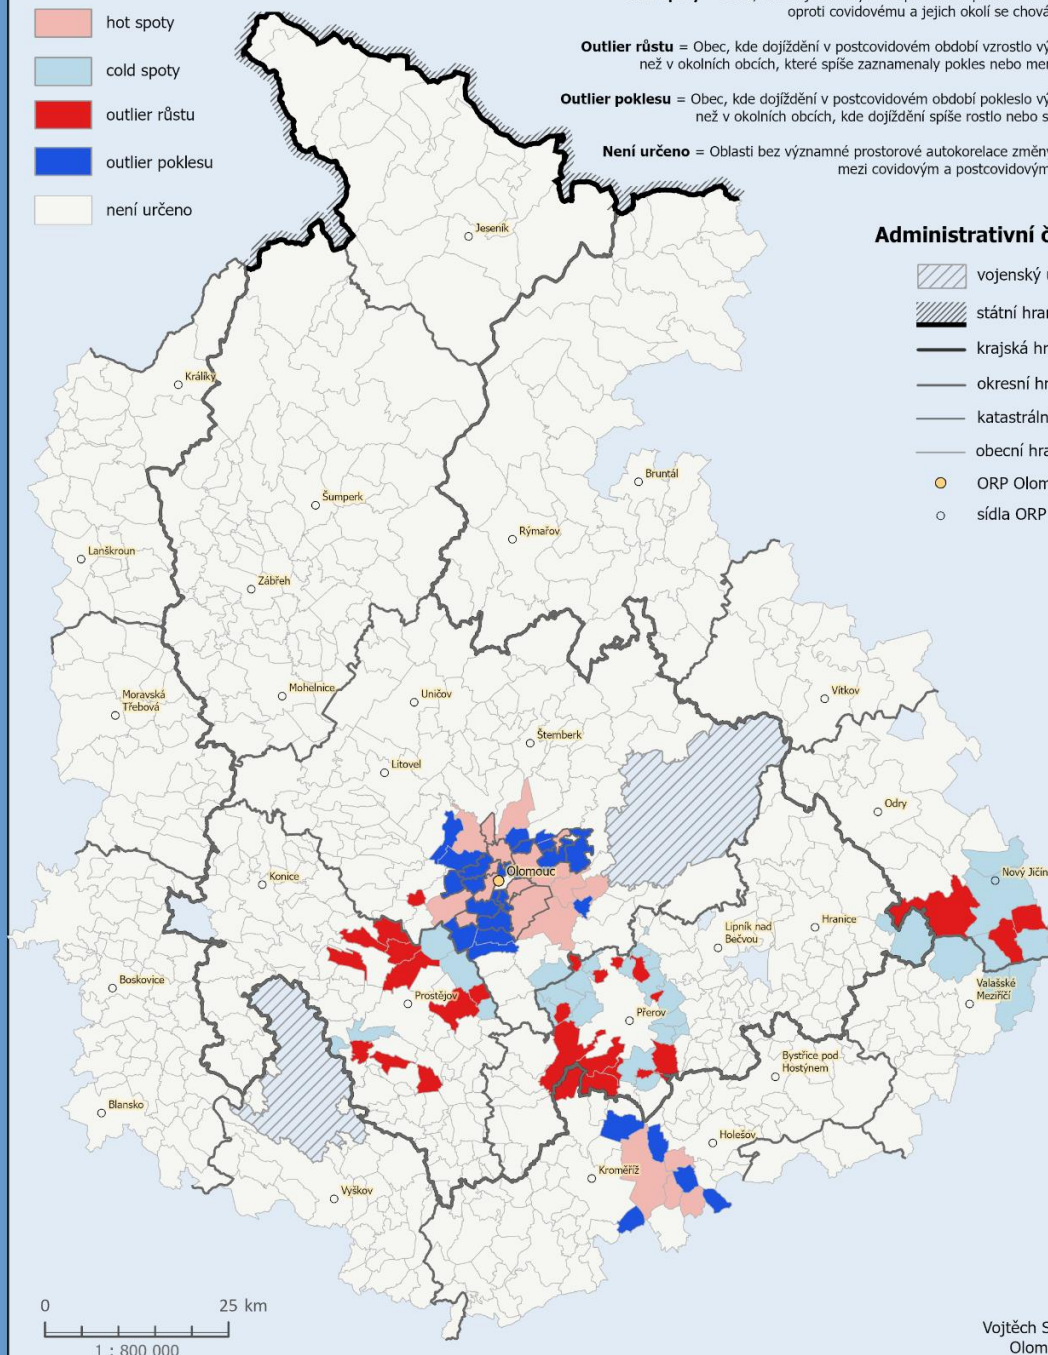
Outlier poklesu = Obec, kde dojíždění v postcovidovém období pokleslo výrazně více než v okolních obcích, kde dojíždění spíše rostlo nebo stagnovalo.

Není určeno = Oblasti bez významné prostorové autokorelace změny dojíždění mezi covidovým a postcovidovým obdobím.

- hot spoty
- cold spoty
- outlier růstu
- outlier poklesu
- není určeno

Administrativní členění

- vojenský újezd
- státní hranice
- krajská hranice
- okresní hranice
- katastrální hranice
- obecní hranice
- ORP Olomouc
- sídla ORP




Vojtěch SVOBODA
Olomouc 2025

ZMĚNA POČTU DOJÍŽDĚJÍCÍCH A PROSTOROVÉ VZORY

pro obce a katastrální území Olomouckého kraje a okolí do 10 km, COVID-19 vs PostCOVID-19

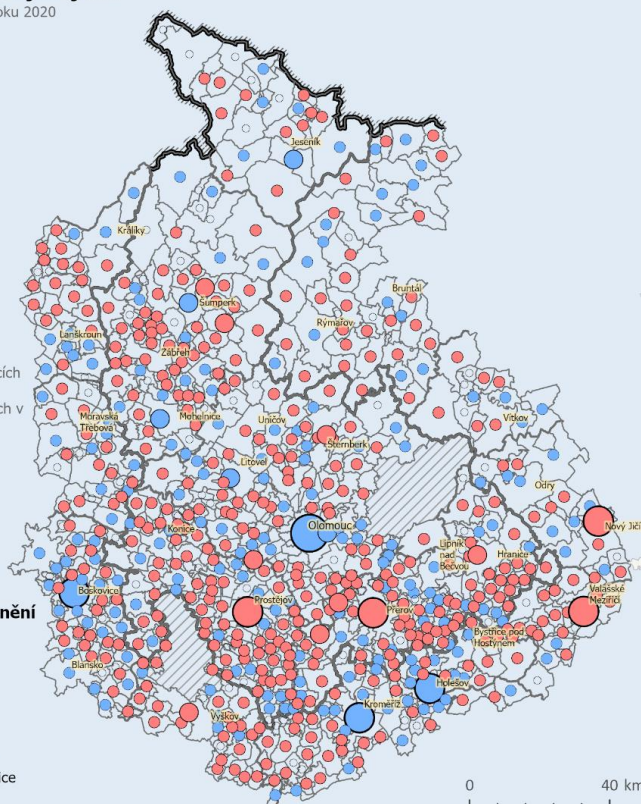
Absolutní změna dojíždějících

rozdíl mezi podzimem roku 2020
a podzimem roku 2022
(2022 - 2020)



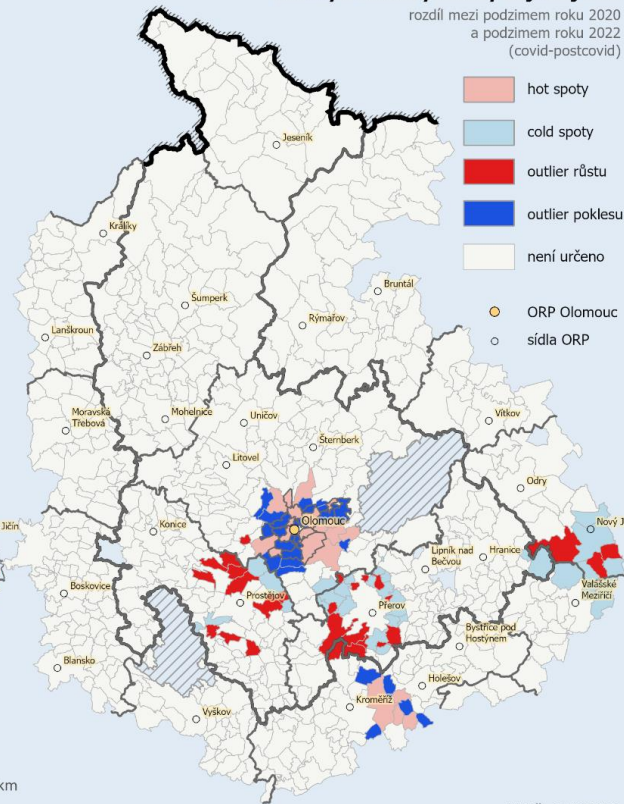
červená = více dojíždějících
v období Covidu-19
modrá = více dojíždějících
v období po Covidu-19

Administrativní členění



Shluky a outliery změny dojíždějících

rozdíl mezi podzimem roku 2020
a podzimem roku 2022
(covid-postcovid)









Vojtěch SVOBODA
Olomouc 2025

POČET REZIDENTŮ (MPD VS SLDB 2021)

v obcích Olomouckého kraje a obcích vzdálených do 10 km

Administrativní členění

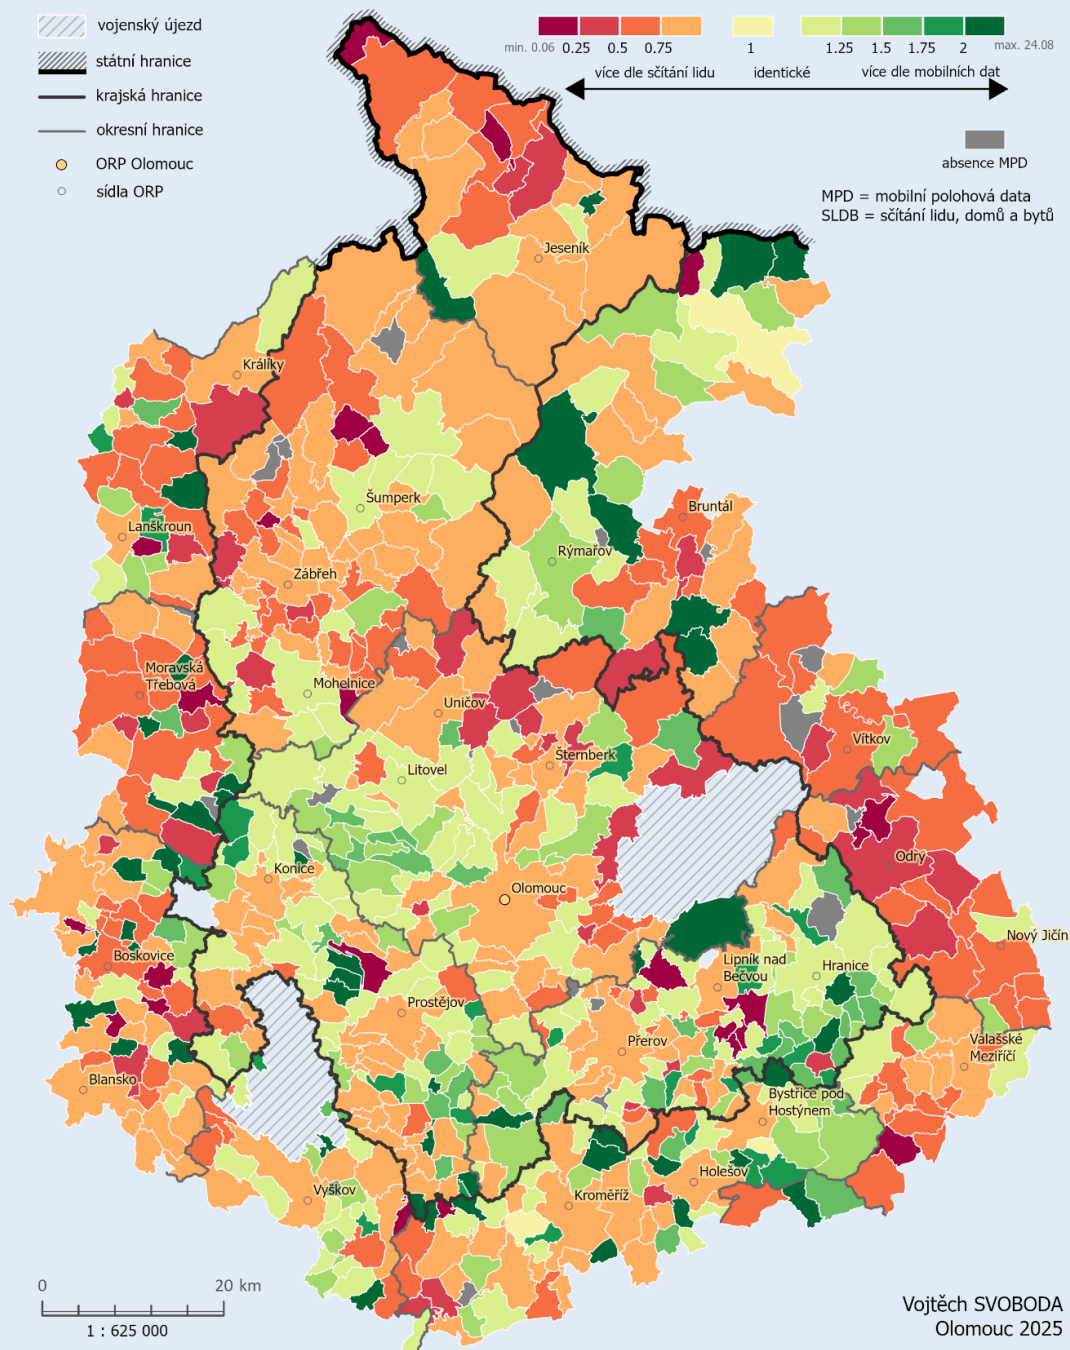
-  vojenský újezd
-  státní hranice
-  krajská hranice
-  okresní hranice
-  ORP Olomouc
-  sídla ORP

Relativní podíl rezidentů dle MPD vůči SLDB 2021



absence MPD

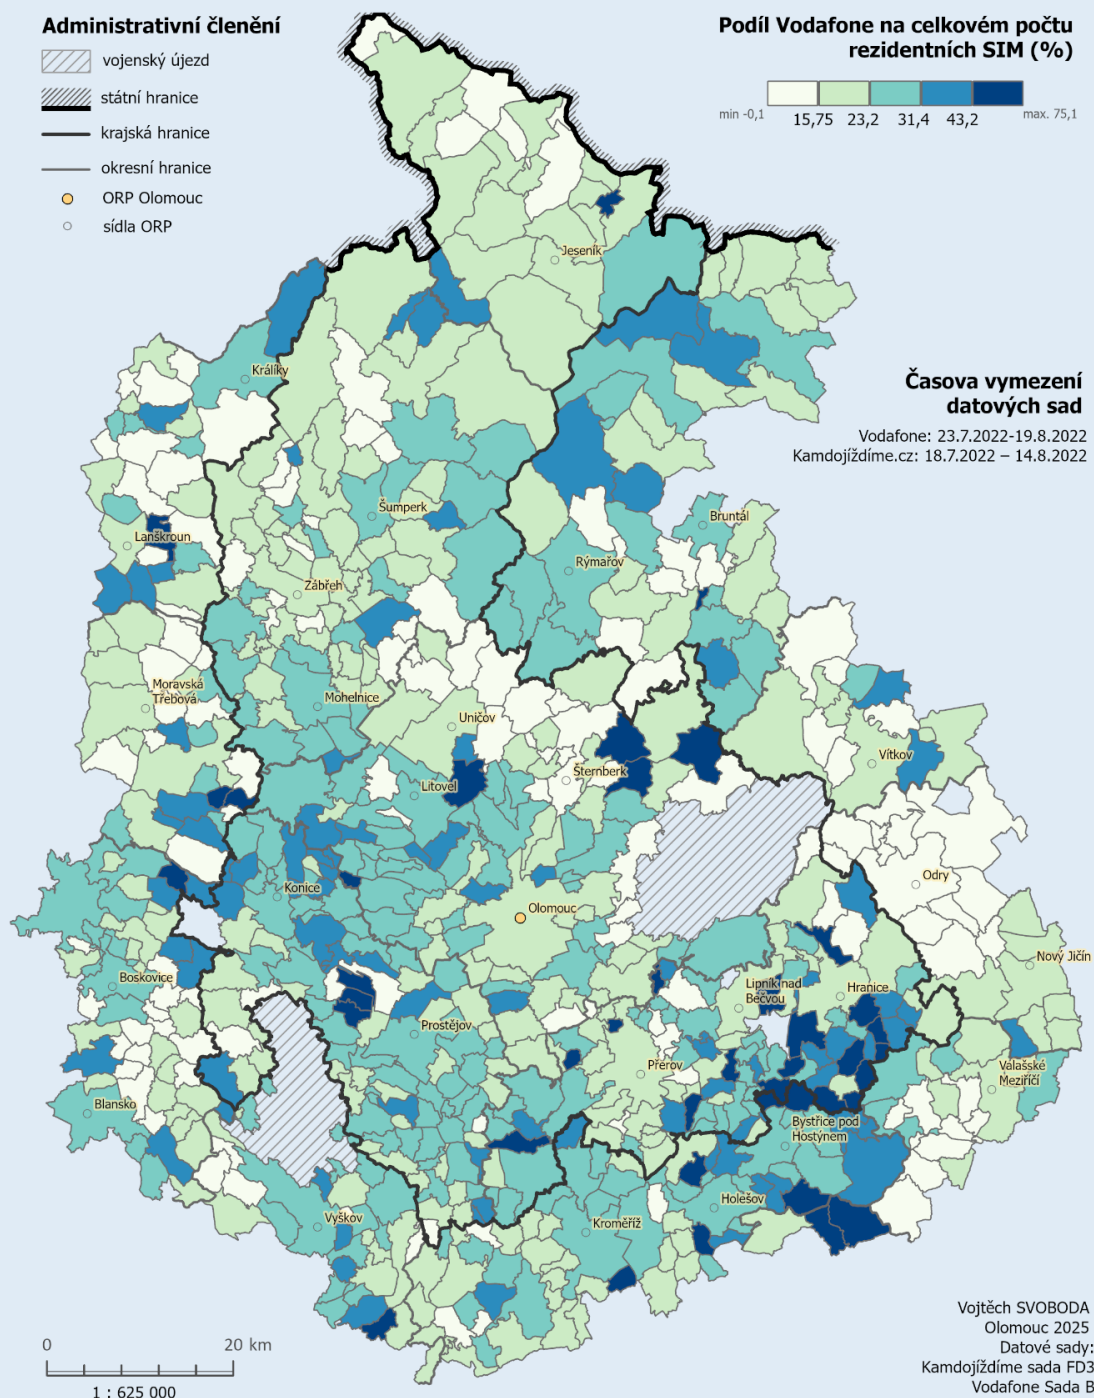
MPD = mobilní polohová data
SLDB = sčítání lidu, domů a bytů



Příloha 22 Validace dat: Srovnání počtu rezidentů dle mobilních polohových dat Vodafone, oproti datům ze sčítání lidu, domů a bytů v roce 2021

POROVNÁNÍ POČTU REZIDENČNÍCH SIM VODAFONE VŮČI AGREGOVANÝM DATŮM MOBILNÍCH OPERÁTORŮ

v obcích Olomouckého kraje a do 10 km, období léto 2022



Příloha 23 Validace dat: Porovnání počtu rezidentních SIM Vodafone vůči agregovaným datům mobilních operátorů ze serveru kamdojizdime.cz

MOBILITA REZIDENTŮ

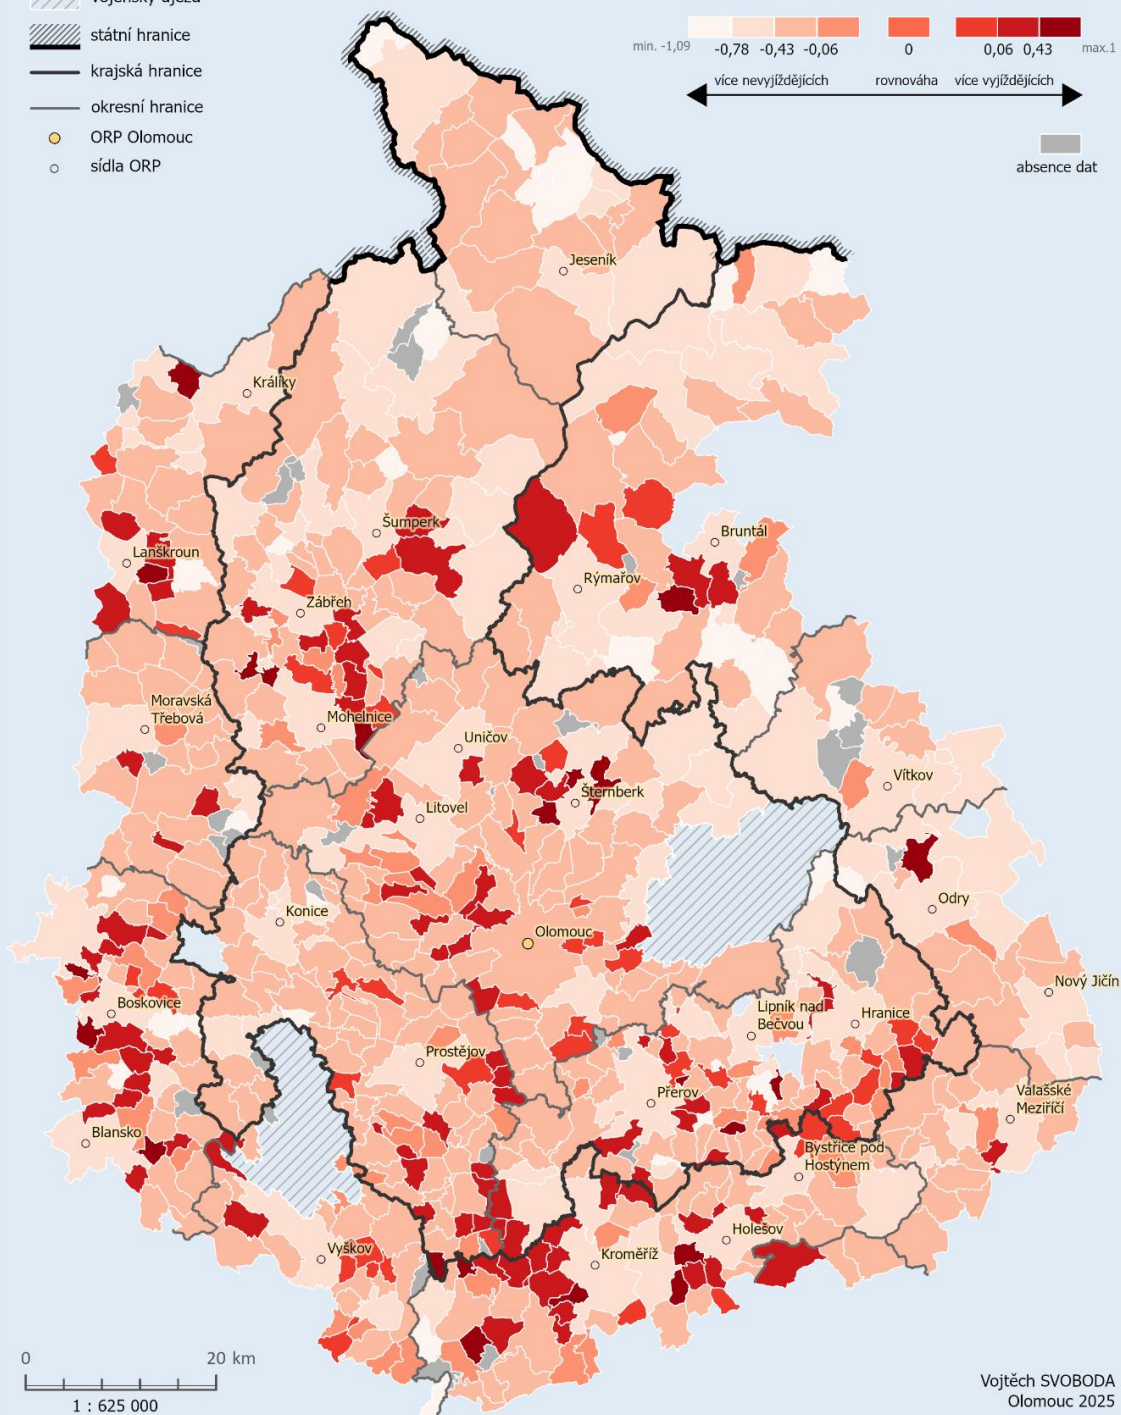

v obcích Olomouckého kraje a obcích vzdálených do 10 km

Administrativní členění

-  vojenský újezd
-  státní hranice
-  krajská hranice
-  okresní hranice
-  ORP Olomouc
-  sídla ORP

Relativní bilance vyjíždějících a nevyjíždějících







Relativní bilance = (vyjíždějící - nevyjíždějící) / rezidenti



POROVNÁNÍ DOJÍŽDKY A VYJÍŽDKY

v obcích Olomouckého kraje a obcích vzdálených do 10 km

Administrativní členění

-  vojenský újezd
-  státní hranice
-  krajská hranice
-  okresní hranice
-  ORP Olomouc
-  sídla ORP

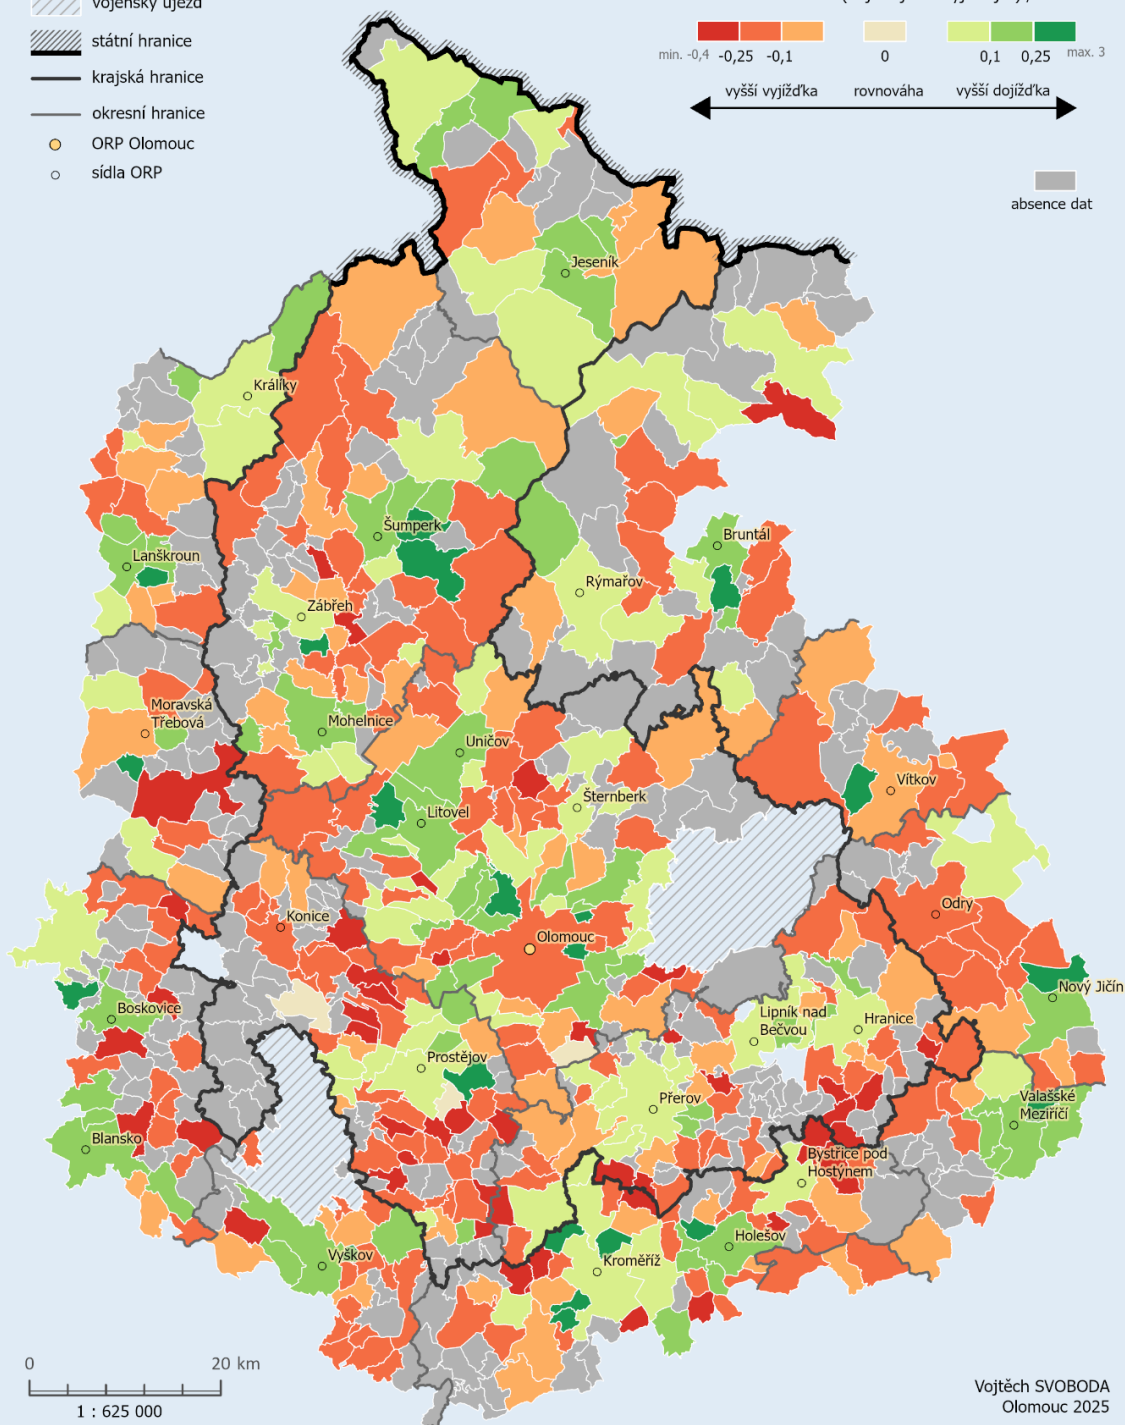
Relativní bilance dojížd'ky

Relativní bilance = (dojíždějící – vyjíždějící) / rezidenti

min. -0,4 -0,25 -0,1 0 0,1 0,25 max. 3

← vyšší vyjížd'ka rovnováha vyšší dojížd'ka →


 absence dat



RELATIVNÍ BILANCE DOJÍŽDKY A MOBILITA REZIDENTŮ

v obcích Olomouckého kraje a obcích vzdálených do 10 km

**Relativní bilance dojížd'ky a míra
vyjíždějících rezidentů**



Relativní bilance dojížd'ky
(dojíždějící - vyjíždějící) / rezidenti
vyšší hodnota = více osob dojíždí, než odjíždí

Relativní bilance rezidentů
(vyjíždějící - nevjíždějící) / rezidenti
vyšší hodnota = více rezidentů opouští obci

absence dat

Vysoká mobilita

- dopravní a pracovní uzly
- soběstačné pracovní obce
- satelitní obce

Střední hodnoty

- obce s kombinovanou funkcí
- uzavřenější stabilní obce
- vyvážené obce
- vyjížd'kové obce s atraktivitou dojíždějících
- standardní vyjížd'kové zázemí

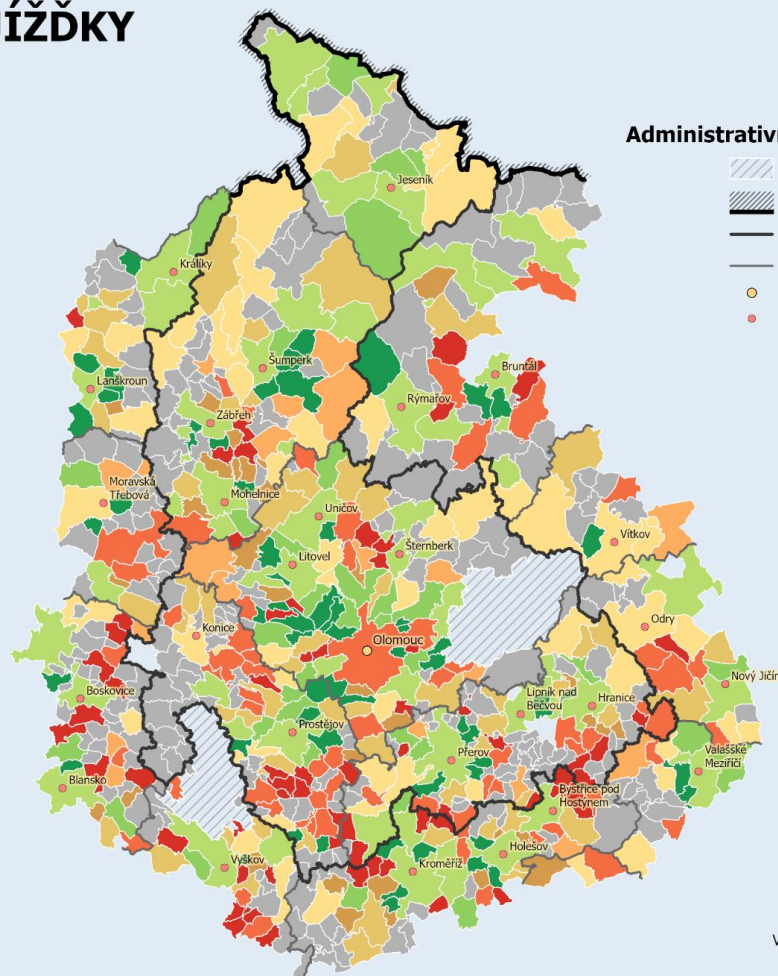
Nízká mobilita

- soběstačné statické obce




Administrativní členění

- vojenský újezd
- státní hranice
- krajská hranice
- okresní hranice
- ORP Olomouc
- sídla ORP




Vojtěch SVOBODA
Olomouc 2025




Příloha 27 Sloupcový graf znázorňující počet obcí v jednotlivých shlucích, všechna dostupná období, K=4

Multivariate Clustering Box-Plots




Příloha 28 Box-plot znázorňující rozdělení vstupních hodnot dle shlukové analýzy, všechna dostupná období, K=4



Příloha 29 Sloupcový graf znázorňující počet obcí v jednotlivých shlucích, všechna dostupná období, K=5

Multivariate Clustering Box-Plots



Příloha 30 Box-plot znázorňující rozdělení vstupních hodnot dle shlukové analýzy, všechna dostupná období, K=5

TYPOLOGIE DLE MOBILITY REZIDENTŮ, DOJÍŽDĚJÍCÍCH A NÁVŠTĚVNÍKŮ

pro obce a katastrální území Olomouckého kraje a okolí do 10km, období léto a podzim 2020 a 2022


Typy obcí na základě shlukové analýzy

dle průměrných hodnot kategorií osob napříč čtyřmi obdobími

- velká města a stabilní venkovské obce s residenční funkcí, ale i mírně vyšší dojížděnkou
- residenční a příměstské oblasti s vyšší dojížděnkou
- menší oblasti s vysokou dojížděnkou
- turistické a rekreační oblasti s vysokou návštěvností
- oblasti smíšeně residenční a návštěvnícké

Administrativní členění


- vojenský újezd
- státní hranice
- krajská hranice
- okresní hranice
- katastrální hranice
- obecní hranice
- ORP Olomouc
- sídla ORP



Vojtěch SVOBODA
Olomouc 2025


2020 a 2022

Features Per Cluster



Příloha 32 Sloupcový graf znázorňující počet obcí v jednotlivých shlucích, léto 2022, K=5

Multivariate Clustering Box-Plots



Příloha 33 Box-plot znázorňující rozdělení vstupních hodnot dle shlukové analýzy, léto 2022, K=5

TYPOLOGIE DLE MOBILITY REZIDENTŮ, DOJÍŽDĚJÍCÍCH A NÁVŠTĚVNÍKŮ


pro obec a katastrální území Olomouckého kraje a okolí do 10km, období léto 2022


Typy obcí dle mobility osob

- statické obce bez výrazné mobility a sezónnosti
- velké obce se statickou mobilitou
- turistické obce
- letní rekreační obce
- letní obytné zázemí

Administrativní členění


- vojenský újezd
- státní hranice
- krajská hranice
- okresní hranice
- katastrální hranice
- obecní hranice
- ORP Olomouc
- sídla ORP





Příloha 35 Sloupcový graf znázorňující počet obcí v jednotlivých shlucích, podzim 2022, K=5

Multivariate Clustering Box-Plots



Příloha 36 Box-plot znázorňující rozdělení vstupních hodnot dle shlukové analýzy, podzim 2022, K=5

TYPOLOGIE DLE MOBILITY REZIDENTŮ, DOJÍŽDĚJÍCÍCH A NÁVŠTĚVNÍKŮ

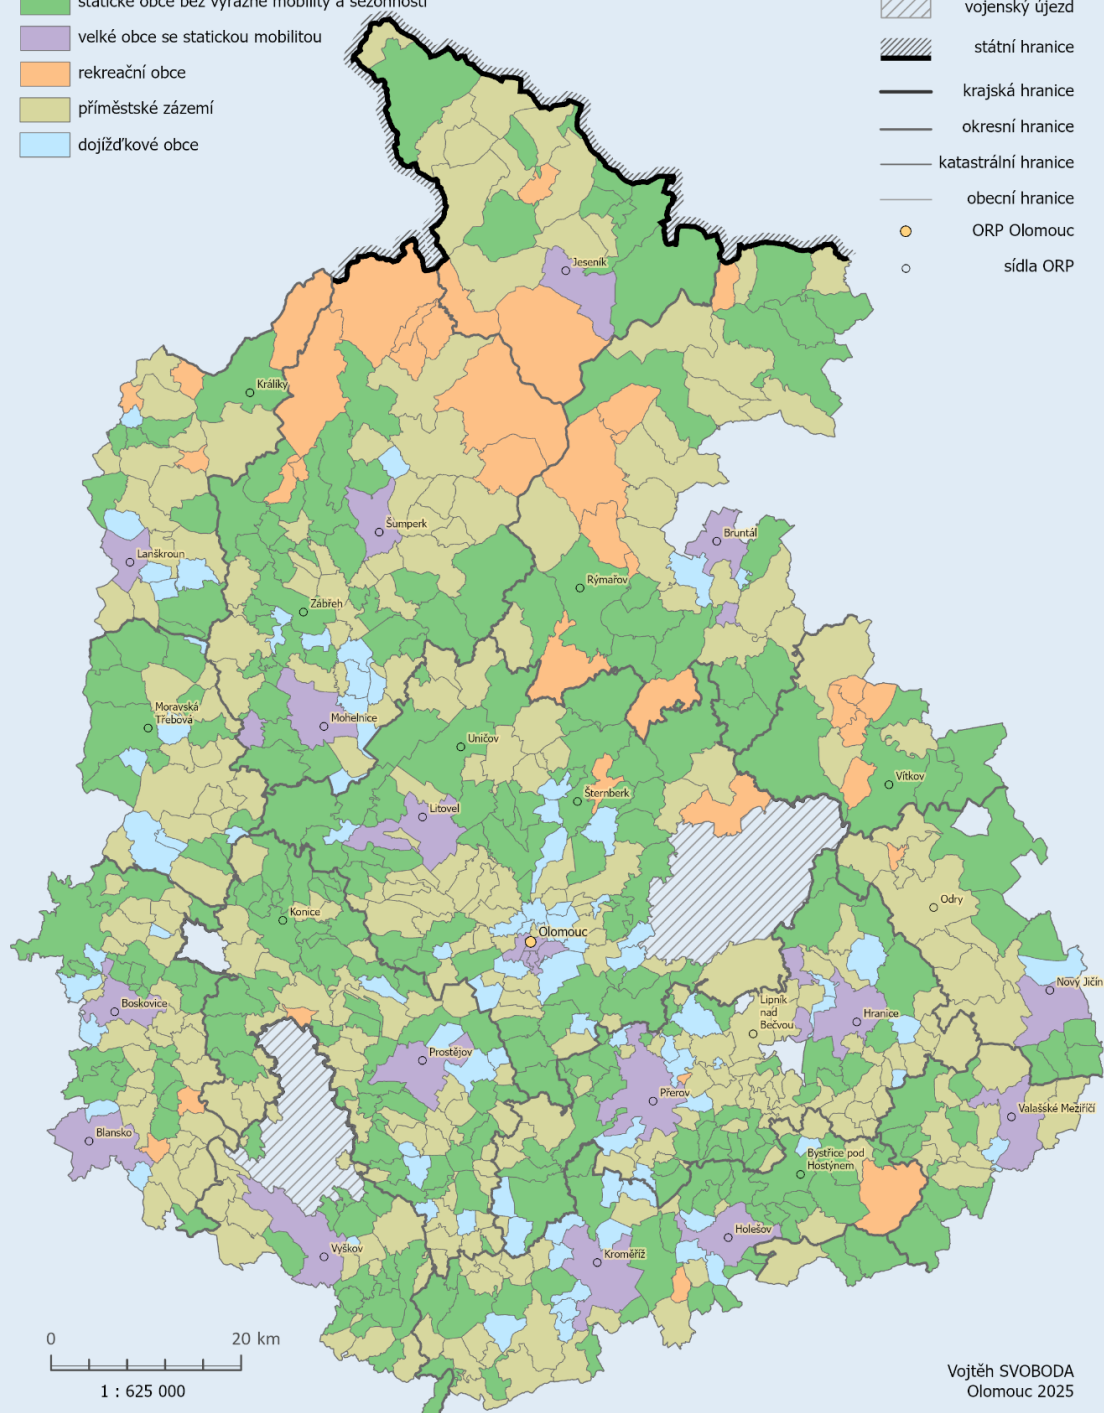
pro obce a katastrální území Olomouckého kraje a okolí do 10 km, období podzim 2022

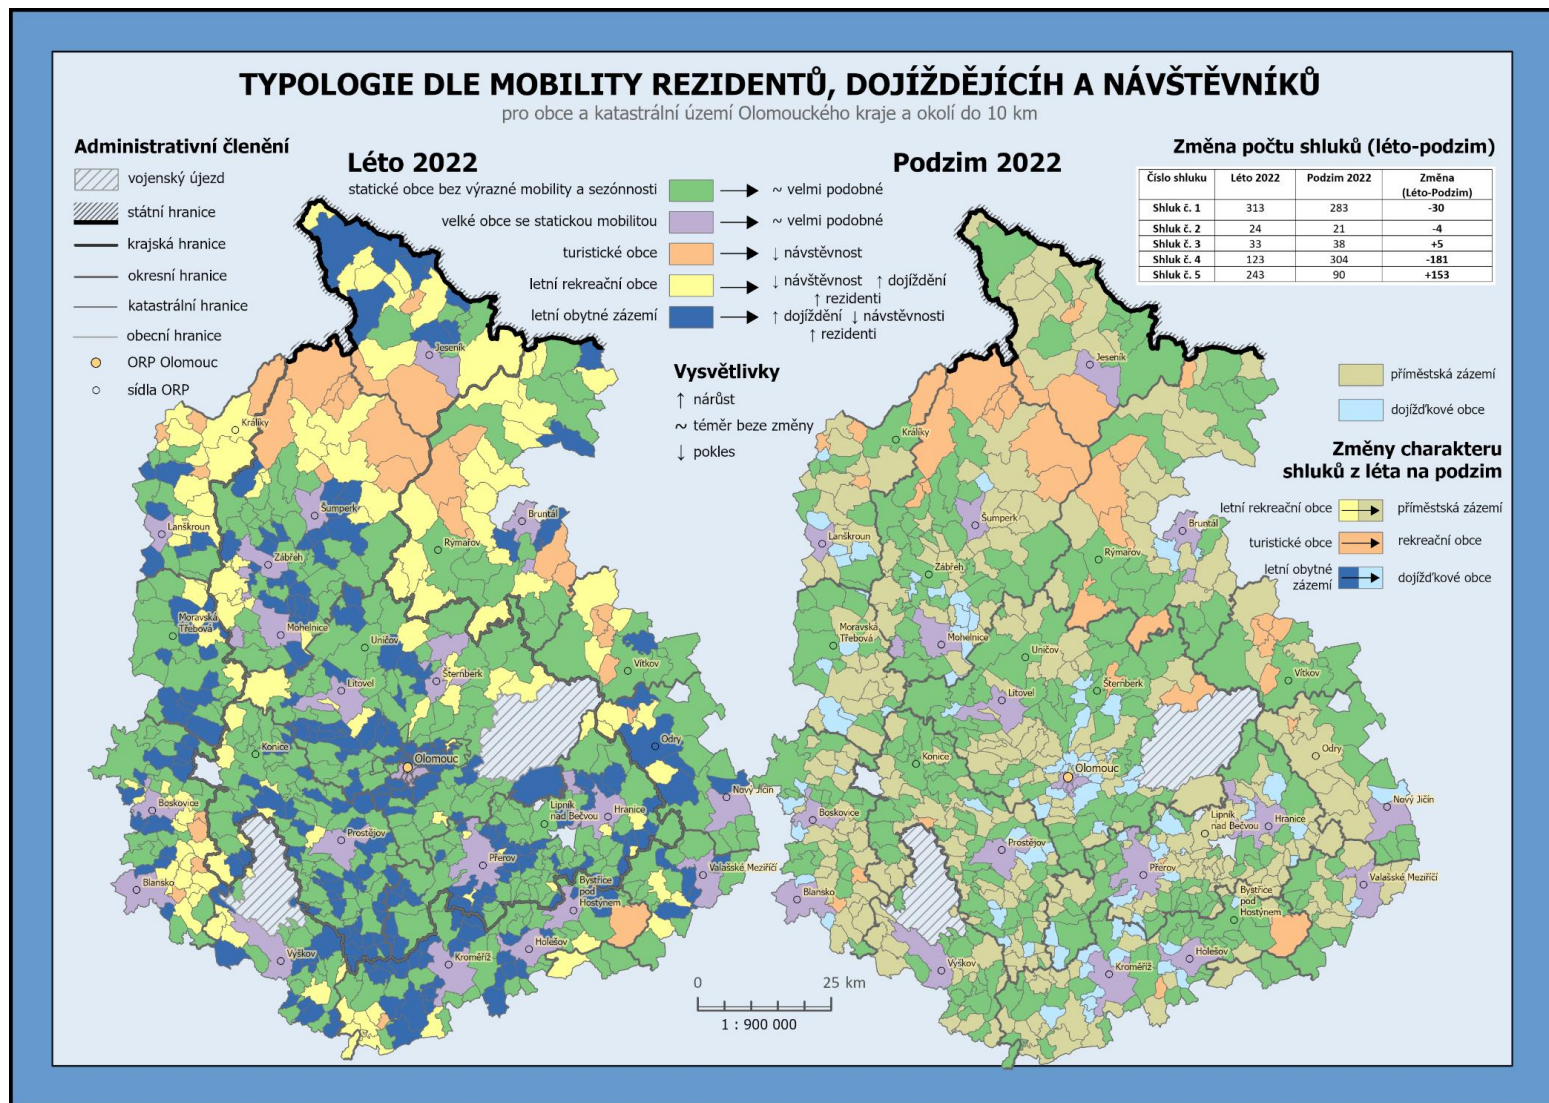
Typy obcí dle mobility osob

- statické obce bez výrazné mobility a sezónnosti
- velké obce se statickou mobilitou
- rekreační obce
- příměstské zázemí
- dojížděkové obce

Administrativní členění

- vojenský újezd
- státní hranice
- krajská hranice
- okresní hranice
- katastrální hranice
- obecní hranice
- ORP Olomouc
- sídla ORP





Príloha 38 Srovnávací mapa typologie rezidentů, dojíždějících a návštěvníků pro podzim a léto 2022