

VYUŽITIE DÁT GOOGLE LOCATION HISTORY PRE VÝSKUM ČASOPRIESTOROVÝCH VZORCOV POHYBU V MESTSKOM PROSTREDÍ

Štefan GÁBOR, Ladislav NOVOTNÝ

Using Google Location History Data to Explore Spatio-Temporal Patterns of Movement in Urban Areas

Abstract: Understanding individual mobility patterns in urban environments requires precise spatiotemporal data that capture the dynamics of everyday movement. Google Location History (GLH) represents a promising source of voluntarily provided geographic information with high spatial and temporal resolution. Despite growing scientific interest, GLH data are still rarely employed for detailed identification of commuting flows within cities. This study demonstrates the potential of GLH for urban mobility research using the example of the city of Košice. The analysis is based on a three-year dataset (2022–2024) from one anonymized user, following a workflow that includes data extraction and preprocessing in R, spatial transformation into a regular grid, and application of Space Time Pattern Mining tools in ArcGIS Pro. By employing a 2D space-time cube and time series clustering methods, we identified stable spatial locations of daily activity and consistent commuting patterns. The results suggest that GLH can reveal the temporal stability of individual mobility patterns and identify key locations of daily activity for the observed user. The study provides a methodological contribution demonstrating the suitability of GLH for urban mobility research while opening avenues for the development of new analytical approaches to the study of individual movement in urban environments.

Keywords: Google Location History, spatio-temporal analysis, urban mobility, time-series clustering, Košice

Úvod

V mestskom prostredí predstavuje pohyb jednotlivcov kľúčový prejav časopriestorovej dynamiky každodenných aktivít. Priestorové a časové rozloženie pohybu obyvateľov poskytuje dôležité informácie o fungovaní mestského systému, ktoré statické ukazovatele populácie či infraštruktúry nedokážu zachytiť. Tradičné populačné dáta z cenzov alebo evidencie obyvateľstva preto neumožňujú analyzovať tieto dynamické formy mobility. S rozvojom digitálnych technológií a senzorných dát sa však otvárajú nové možnosti zachytávania, analýzy a interpretácie časopriestorových vzorcov pohybu. Jedným z možných zdrojov informácií o mobilite sú údaje z Google Location History (GLH), ktoré pri rešpektovaní zásad ochrany súkromia umožňujú detailne analyzovať časopriestorové vzorce individuálneho pohybu. Na ich základe je možné skúmať dynamiku denných aktivít, opakujúce sa mobilné rutiny či využívanie rôznych častí mesta.

Smartfóny a pasívne zbierané lokalizačné údaje predstavujú nový zdroj informácií, ktorý umožňuje zachytiť dlhodobé a individuálne časopriestorové vzorce pohybu. Jedným z najrozšírenejších systémov tohto typu je GLH, ktorý zaznamenáva polohu používateľa prostredníctvom zariadení so systémom Android alebo iOS v prípade, že je nainštalovaná aplikácia Google Maps a povolené lokalizačné služby (Hystad et al., 2022). Ako uvádzajú Pászto et al. (2021), v porovnaní s údajmi mobilných operátorov sú GLH dáta spravidla presnejšie, keďže poloha zariadenia sa neurčuje iba na základe blízkosti základňových staníc (BTS), ale aj prostredníctvom Wi-Fi sietí

Mgr. Štefan GÁBOR, PhD., doc. Mgr. Ladislav NOVOTNÝ, PhD., Ústav geografie, Prírodovedecká fakulta, Univerzita Pavla Jozefa Šafárika v Košiciach, Jesenná 5, 040 01 Košice, e-mail: stefan.gabor@upjs.sk, ladislav.novotny@upjs.sk

a GPS signálu, ktorý poskytuje vysoké priestorové rozlíšenie. Tieto dáta zároveň umožňujú odlišiť, či sa používateľ pohyboval určitým dopravným prostriedkom, alebo zotrval na jednom mieste, a poskytujú aj informáciu o presnosti zaznamenatej polohy. Hoci Google tieto údaje využíva najmä pre interné analytické účely, každý používateľ má možnosť svoje dáta exportovať prostredníctvom služby Google Takeout vo formáte JSON a ďalej ich spracovávať alebo vizualizovať v prostredí GIS či štatistických softvérov.

Mestská mobilita vyjadruje podľa De Oliveira et al. (2017) spôsob, akým sa ľudia pohybujú v mestských oblastiach, pričom sa berú do úvahy všetky spôsoby dopravy. Nové teoretické a metodologické prístupy, založené na priestorovo lokalizovanom zbere dát a analýze geolokalizovaných digitálnych stôp, otvárajú možnosti pre hlbšie pochopenie prepojenia medzi mobilitou a priestorom v mestskom prostredí (Cagney et al., 2020). Koncept urbánnej mobility je preto úzko spätý s pojmom aktívneho priestoru (activity space), ktorý zahŕňa priestorové kontexty každodenných aktivít jednotlivcov, nielen ich bydlisko, ale aj miesta, kde sa pohybujú, pracujú či trávajú voľný čas (Browning a Soller, 2014; Cagney et al., 2013).

Výskum urbánnej mobility sa opiera o široké spektrum dátových zdrojov, ktoré zachytávajú rôzne formy pohybu ľudí v mestskom priestore. Tieto zdroje sa líšia mierou detailu, spôsobom zberu aj typom dopravného správania, ktoré umožňujú analyzovať. Využívanie týchto dát je spojené s celým spektrom analytických prístupov, od klasických priestorových analýz cez časovo-priestorové modelovanie až po metódy strojového učenia. Konkrétna voľba metód závisí od typu dát, priestorovej mierky a výskumného cieľa. Tradične sa empirické štúdieestskej mobility skúmajú cez dotazníkové zisťovania, v ktorých sa často berie ohľad aj na sociodemografické charakteristiky respondentov (Jiang et al., 2012; Jones a Pebley, 2014; Rode et al., 2015). Moderné technológie využívajúce GPS umožňujú presnejšie a dostupnejšie sledovanie priestorovej mobility obyvateľstva (Pregi et al. 2022). Prinášajú detailný pohľad cez sledovanie osôb alebo vozidiel a umožňujú identifikovať základné trendy mobility v mestskom prostredí (Palmer et al., 2013; Nait-Sidi-Moh et al., 2013; Hadavi et al., 2018). Ďalšou skupinou sú dáta z verejnej dopravy, ktoré poskytujú informácie o pohybe cestujúcich na základe využívania dopravných kariet alebo iných elektronických systémov (Cats a Ferranti, 2022; Cats, 2024). Špecifickú skupinu tvoria práce využívajúce dáta od mobilných operátorov (Mamei a Colonna, 2016; Jiang et al., 2017; Šveda a Barlik, 2018), či dáta z lokalizačných záznamov sociálnych sietí ako Twitter (Luo et al., 2016; Miyazawa et al., 2019). V posledných rokoch sa ako relevantný zdroj informácií o urbánnej mobilite ukazujú aj dáta z mikromobility, ktoré detailne zachytávajú využívanie rôznych dopravných prostriedkov. Ide o využívanie bicyklov a e-bicyklov (Li et al., 2023; Kong et al., 2025), kolobežiek a e-kolobežiek (Zuniga-Garcia et al., 2021; Pazzini et al., 2022), skútrov (Arias-Molinares et al., 2021), prípadne kombináciu viacerých dopravných prostriedkov naraz, čím je možné porovnávať priestorové vzorce pohybu užívateľov a identifikovať funkčné oblasti v rámci mesta (Gábor et al., 2025).

GLH predstavuje nový a perspektívny zdroj časopriestorových údajov o individuálnej mobilite, čo v posledných rokoch dokumentuje jeho využitie vo viacerých výskumných oblastiach. V oblasti dopravného výskumu sa využíva ako alternatíva k tradičným cestovným denníkom, keďže umožňuje detailne sledovať trajektórie pohybu jednotlivcov a identifikovať pravidelné vzorce správania (Cools et al., 2021; Löchtefeld, 2019). GLH dáta zároveň slúžia na analýzu zmien dopravného správania v dôsledku spoločenských alebo environmentálnych udalostí, ako napríklad pandémie COVID-19 (Pászto et al., 2021; Periyasamy a Venkatesh, 2021). Ich vysoké časové rozlíšenie umožňuje študovať jemné priestorové rozdiely a kvantifikovať mobilitu na úrovni jednotlivcov, či mestských štvrtí (Ruktanonchai, 2018). Významný prínos majú aj v environmentálnych a zdravotných výskumoch, kde pomáhajú odhadovať expozíciu obyvateľov environmentálnym rizikám a znečisteniu ovzdušia (Hystad et al., 2022; Yu et al., 2021). Súčasne sa skúma aj presnosť a potenciálne chyby lokalizácie, keďže kvalita dát je ovplyvnená rôznymi faktormi, ako sú GPS signál, hustota Wi-Fi sietí či typ zariadenia (Macarulla Rodriguez et al., 2018). Uvedené štúdie realizujú výskum s využitím GLH dát zväčša vo väčších priestorových mierkach, najmä na medziobecnej úrovni alebo úrovni celých regiónov. Výskum zameraný na detailnú vnútrómestskú analýzu však zostáva nedostatočne zastúpený, čo podčiarkuje potrebu rozvíjať prístupy schopné zachytiť aj jemnejšie rozdiely a priestorové vzorce v rámci menšieho prostredia.

Hoci údaje z GLH sa využívajú vo výskume priestorovej mobility, väčšina existujúcich štúdií sa zameriava predovšetkým na všeobecné časopriestorové vzorce pohybu alebo zmeny mobility v dôsledku mimoriadnych udalostí, akou bola napríklad pandémia COVID-19. Výskum zameraný na identifikáciu dochádzkových tokov z GLH dát doposiaľ prakticky absentuje, a to napriek tomu, že dochádzka do zamestnania patrí medzi najvýznamnejšie formy každodennej mobility obyvateľov. Naša štúdia má ambíciu prispieť k vyplneniu tejto výskumnej medzery. Cieľom štúdie je demonštrovať potenciál údajov z GLH na analýzu časopriestorových vzorcov individuálnej mobility so zameraním na identifikáciu opakujúcich sa mobilityných rutín, ktoré môžu indikovať dochádzkové správanie, prostredníctvom časopriestorových metód v prostredí ArcGIS Pro.

1. Dáta a metódy

Prístupy k štúdiu a využívaniu GLH dát sa z hľadiska využívania metód rôznia podľa účelu a zamerania štúdie. Väčšinou ide o porovnávanie kvality záznamov GLH a GPS loggerov (Ruktanonchai, 2018; Cools et al., 2021; Yu et al., 2021) pričom sa často využívajú matematicko-štatistické techniky či funkcie kumulatívnej distribúcie na hodnotenie presnosti merania (Rodríguez et al., 2018). Ďalšia časť výskumov pracuje s priestorovou agregáciou údajov do gridov alebo hexagonálnych sietí s následnou aplikáciou hotspotových a hustotných analýz (Pászto et al., 2021), čím sa však potláčajú časové rytmy každodenného správania jednotlivcov. Analytické prístupy, ktoré naplno využívajú dynamickú časopriestorovú štruktúru GLH sú stále v menšine. To platí najmä pri identifikácii pravidelností v priestorových vzorcoch obyvateľstva. S cieľom zachytiť stabilitu priestorových lokalít dochádzky v čase a odhaliť pravidelné rytmy každodenného pohybu sme sa rozhodli aplikovať 2D časopriestorovú kocku a metódy časopriestorového zhľukovania.

1.1 Dáta a postup ich spracovania

Analýzu priestorovej mobility jednotlivca sme založili na využití lokalizačných údajov zo služby GLH. Ide o dobrovoľne poskytované dáta, ktoré vznikajú sledovaním polohy mobilného zariadenia prostredníctvom aktívneho účtu Google so zapnutými lokalizačnými službami. Dáta v tejto štúdií sú použité so súhlasom používateľa, ktorý ich na tento účel poskytol dobrovoľne. Z dôvodu ochrany súkromia boli údaje anonymizované, t. j. neobsahujú žiadne osobné identifikátory a nie je možné späťne určiť identitu používateľa. Navyše, priestorová informácia bola transformovaná do pravidelnej mriežky s veľkosťou bunky 250×250 m, čím sa minimalizuje riziko identifikácie citlivých lokalít a zároveň sa zachováva priestorová informácia potrebná pre analýzu dochádzkových vzorcov. Dáta sa ukladajú v účte Google používateľa a možno ich exportovať vo formáte KML alebo JSON v podobe, ako ilustruje nasledujúca ukážka.

```
{
  "locations": [
    {
      "latitudeE7": 487289525,
      "longitudeE7": 212495312,
      "accuracy": 19,
      "altitude": 259,
      "verticalAccuracy": 1,
      "timestamp": "2022-04-11T10:18:20.134Z",
      "deviceTag": 1,
      "source": "WIFI",
      "deviceTag": 87851058,
      "platformType": "ANDROID",
      "locationMetadata": {
        "wifiScan": [
          {
```

```
"mac": "140298705351806",  
"strength": -49,  
"frequencyMhz": 2462  
}
```

Dataset obsahuje podrobné informácie o polohe a aktivite zariadenia, vrátane:

- geografických súradníc (*latitude, longitude*),
- presnosti merania (*accuracy*),
- nadmorskej výšky (*altitude*),
- typu aktivity (napr. chôdza, jazda dopravným prostriedkom),
- pravdepodobnosti priradenia aktivity (*confidence*, 0 – 100),
- časového záznamu (*timestamp*),
- identifikačných premenných zariadenia (*source, deviceTAG, platform type*),
- a prístupových bodov Wi-Fi (frekvencia, MAC adresa, sila signálu).

Výhodou týchto dát je ich pravidelné, automatické a dlhodobé zaznamenávanie, ktoré umožňuje analyzovať priestorové správanie používateľa v detailnom časovom rozlíšení. Nevýhodou je zložitá vnútorná štruktúra exportovaných súborov (najmä vo formáte JSON), ktorá si vyžaduje predspracovanie a extrakciu relevantných premenných pomocou programovacích nástrojov alebo softvérov GIS.

Napriek týmto obmedzeniam predstavujú lokalizačné dáta od spoločnosti Google cenný zdroj informácií o individuálnej mobilite. Umožňujú identifikovať dochádzkové a každodenné pohybové vzorce s vysokou priestorovou aj časovou presnosťou, osobitne v mestskom prostredí. Výzvou pre rozsiahlejší výskum je tiež získanie dát dostatočne veľkej a reprezentatívnej vzorky užívateľov, čo by umožnilo komplexnejšie pochopiť priestorové organizovanie každodenného pohybu a presnejšie identifikovať funkčné zóny v mestách a analyzovať ich využívanie v čase.

Pôvodný dátový súbor vo formáte JSON obsahoval podrobné záznamy o polohe používateľa. Na jeho spracovanie sme vytvorili skript v prostredí RStudio (verzia 2024.04.1 Build 748), ktorého cieľom je extrahovať, vyčistiť a priestorovo i časovo obmedziť údaje na záujmové obdobie a územie mesta Košice (obr. 1).

Vstupné údaje boli načítané pomocou knižnice *jsonlite*, ktorá previedla štruktúru *json* do dátového rámca. Z atribútu *timestampMs* bol odvodený dátum a čas (vo formáte *POSIXct*), pričom súradnice *latitudeE7* a *longitudeE7* boli prepočítané delením miliónom na štandardné súradnice vo formáte WGS 84.

Následne boli údaje filtrované na obdobie rokov 2022 až 2024 a priestorovo obmedzené na územie mesta Košice (na základe súradníc hraníc mesta). Po tejto selekcii boli do datasetu pridané nové premenné: deň v týždni (*day_of_week*) a kategorizácia dňa na pracovný deň alebo víkend (*type_of_day*).

Do ďalšieho spracovania boli vybrané iba relevantné premenné (*date, hour, latitude, longitude, day_of_week, type_of_day, accuracy*) a pripravené na export do formátu *.csv*, ako vstupný súbor pre spracovanie v prostredí ArcGIS Pro (verzia 3.5.3.).

Výsledný dataset má jednoduchú a prehľadnú štruktúru (tab. 1) a obsahuje viac ako 169 000 záznamov pre pracovné dni, pomocou ktorých vieme identifikovať výskyt používateľa v priestore a čase.

```

1 #Knižnice
2 install.packages(c("jsonlite", "dplyr", "lubridate", "sf", "readr"))
3 library(jsonlite)
4 library(dplyr)
5 library(lubridate)
6 library(sf)
7 library(readr)
8 library(anytime)
9
10 # Výber JSON súboru
11 file_path <- file.choose()
12 # file_path <- "C:/Users/Gábor/Desktop/PhD/DATA/GOOGLETML/datasets/Records.json"
13
14 # Načítanie dát
15 data_list <- fromJSON(file_path)
16 data <- data_list$locations
17
18 # Konverzia timestampu na použiteľný dátum a čas
19 data <- data %>%
20   mutate(
21     time = as.POSIXct(as.numeric(timestampMs) / 1000, origin = "1970-01-01", tz = "UTC"),
22     date = as.Date(time),
23     hour = format(time, "%H:%M:%S"),
24     latitude = latitudeE7 / 1e7,
25     longitude = longitudeE7 / 1e7
26   )
27
28 # Filtrovanie dát pre obdobie 2022 - 2024
29 data <- data %>%
30   filter(time >= as.POSIXct("2022-01-01", tz = "UTC") & time <= as.POSIXct("2024-12-31", tz = "UTC"))
31
32 # Filtrovanie pre lokalitu Košice
33 data <- data %>%
34   filter(latitude >= 48.6 & latitude <= 48.8, longitude >= 21.2 & longitude <= 21.3)
35
36 # Pridanie dňa v týždni a kategorizácia na Workday / Weekend
37 data <- data %>%
38   mutate(
39     day_of_week = weekdays(date, abbreviate = FALSE), # Získa deň v týždni
40     type_of_day = ifelse(day_of_week %in% c("Saturday", "Sunday"), "Weekend", "Workday")
41   )
42
43 # Výber finálnych stĺpcov pre export
44 data_final <- data %>%
45   select(date, hour, latitude, longitude, day_of_week, type_of_day, accuracy)
46
47 # Export do CSV
48 write_csv(data_final, "C:/Users/Gábor/Desktop/PhD/DATA/GOOGLETML/datasets/data_filtered.csv")
49
50 print("CSV úspešne exportované!")

```

Obr. 1 Ukážka kódu na spracovanie dát v prostredí RStudio

Tab. 1 Finálna štruktúra datasetu pre analýzu časopriestorových vzorcov

dátum	čas	lat	lon	deň	typ dňa
6.1.2022	14:40:43	48.709820	21.261594	štvrtok	pracovný deň
6.1.2022	14:57:17	48.709820	21.261594	štvrtok	pracovný deň
6.1.2022	15:00:35	48.709820	21.261594	štvrtok	pracovný deň
6.1.2022	15:01:48	48.709824	21.261526	štvrtok	pracovný deň
...
31.12.2024	23:54:13	48.709764	21.261504	utorok	pracovný deň

1.2 Tvorba 2D časopriestorovej kocky

2D časopriestorová kocka predstavuje analytický model, ktorý umožňuje agregovať priestorové udalosti do pravidelnej mriežky a zároveň zachovať ich časovú dimenziu. Výsledkom je multidimenzionálna štruktúra, ktorá umožňuje sledovať vývoj intenzity priestorovej aktivity v čase a odhaliť dlhodobé trendy v mobilite obyvateľov. Tento prístup poskytuje robustný základ na detekciu zmien a vzorcov správania bez straty priestorovej presnosti (ESRI, 2025a).

Tvorbu časopriestorovej kocky sme realizovali v prostredí ArcGIS Pro, pričom sme využili nástroje samostatného toolboxu (*Space Time Pattern Mining toolbox*). Tento nástroj umožňuje vytvárať kocku tromi spôsobmi – agregáciou bodov, z definovaných lokalít alebo z multidimenzionálnych rastrových vrstiev. V našom prípade bola použitá prvá možnosť, teda agregácia bodov do časopriestorovej štruktúry *netCDF*.

Každý priestorovo-časový priečinok (bin) v kocke obsahuje počet udalostí, ktoré sa v danom mieste vyskytli počas časového intervalu. Pre každú jednotku sú zároveň počítané základné štatistiky atribútov. Výsledkom je časopriestorová kocka, ktorá môže byť vizualizovaná v 2D alebo v 3D podobe.

2D časopriestorová kocka predstavuje dvojrozmernú vizualizáciu trendov odvodených z 3D štruktúry. Pre každú priestorovú jednotku (mriežku) je aplikovaný Mann-Kendallov štatistický test, ktorého výsledkom sú tri hlavné ukazovatele:

- Trend (*Trend Type*) – identifikuje, či v danom mieste dochádza k výraznému nárastu, poklesu, alebo absencii trendu v intenzite priestorovej aktivity.
- P-hodnota (*p-value*) – určuje pravdepodobnosť, že zistený trend je náhodný. Čím nižšia hodnota, tým významnejší trend.
- Z-skóre (*z-score*) – udáva silu a smer trendu. Pozitívna hodnota znamená nárast, negatívna pokles. Čím je hodnota vzdialenejšia od nuly, tým je trend silnejší.

Tieto ukazovatele umožňujú identifikovať časti územia s rastúcou alebo klesajúcou mobilitou v čase.

Do analýzy boli zaradené iba záznamy z pracovných dní. Časopriestorová kocka bola vytvorená pre veľkosť mriežky 250×250 m v priestorovo projektovanom systéme *ETRS 1989 UTM Zone 34N*. Takto vytvorená časopriestorová kocka tvorila východisko pre aplikáciu ďalších metód zhľukovania časových radov. Záujmové územie je vymedzené priamo priestorovým rozsahom pohybu používateľa, ktorý determinuje dostupnosť a výskyt aktivít v danom prostredí. Takto definovaná priestorová vzorka umožňuje identifikovať stabilné a každodenné dochádzkové vzorce a zároveň odhaliť funkčnú štruktúru mesta, čo korešponduje s poznatkami o priestorovej diferenciacii dochádzky v meste (Gábor a Pergi, 2023).

1.3 Metódy zhľukovania časových radov

Nástroj *Time Series Clustering* (TSC) identifikuje priestory s podobným časovým vývojom v rámci časopriestorovej kocky. Zoskupuje ich do zhľukov, v ktorých majú časové rady najpodobnejšie charakteristiky. Ako vstup využíva dátový súbor *netCDF*, pričom ako výstup generuje 2D mapu so zobrazením jednotlivých zhľukov. Súčasťou výsledkov sú aj grafy reprezentatívnych časových radov a voliteľne interaktívne vizualizácie priebehu vývoja pre každú lokalitu.

Cieľom metódy je rozdeliť priestory (mriežky) v časopriestorovej kocke do skupín (zhľukov), s podobným priebehom hodnôt v čase. Podobnosť možno vyjadriť tromi spôsobmi:

1. Hodnotová podobnosť (*Value*): zoskupuje miesta s podobnými absolútnymi hodnotami v čase (euklidovská vzdialenosť).
2. Profilová podobnosť (*Profile Correlation*): zoskupuje miesta s rovnakým trendom vývoja bez ohľadu na absolútne hodnoty. Porovnanie sa vykonáva cez korelačný koeficient. Čím je vyššia pozitívna korelácia, tým je aj vyššia podobnosť.
3. Periodická podobnosť (*Fourier*): sleduje opakujúce sa vzory (napr. denné alebo sezónne cykly), pričom časové rady sú rozložené na Fourierove funkcie (sínusoidy a kosínusoidy), zachytávajúce dominantné periodické signály.

Každý z týchto prístupov umožňuje odhaliť odlišné typy časových štruktúr, od jednoduchého porovnávania hodnôt, cez spoločné trendy, až po cyklické správanie. Detailné objasnenie vybraných prístupov s matematickým vyjadrením prináša ESRI (2025b).

2. Výsledky časopriestorovej kocky priestorového pohybu používateľa počas pracovných dní

Analýza priestorového pohybu používateľa bola realizovaná na dennej časovej úrovni, pričom interval agregácie bol nastavený na 1 deň. Takto zvolená granularita umožňuje zachytiť detailné denné variácie a pravidelnosti v pohybe, predovšetkým dochádzkové vzorce, ktoré by pri agregácii na týždňovej úrovni mohli zostať potlačené. Denný interval navyše umožňuje identifikovať rytmus dochádzky (ranné a popoludňajšie presuny), ako aj jemné rozdiely medzi jednotlivými pracovnými dňami, napríklad odlišné trasy alebo časy dochádzky v pondelok či piatok. Tento prístup preto poskytuje komplexnejší pohľad na časopriestorové vzorce pohybu a presnejšiu interpretáciu opakujúcich sa denných rytmov v mestskom prostredí.

Na základe týchto údajov bola skonštruovaná časopriestorová kocka vo formáte *netCDF*, ktorá je nevyhnutným základom pre nadväzujúce časopriestorové analýzy. Vytvorená kocka agregovala 169 932 bodov do 2 310 mriežkových buniek v rámci 1 091 denných intervalov. Zo všetkých buniek obsahovalo 475 (20,6 %) aspoň jeden záznam v niektorej časovej jednotke, čo predstavuje 518 225 časopriestorových binov, z ktorých 11 129 vykazovalo nenulové hodnoty. Vzhľadom na detailný časový interval časopriestorovú kocku vizualizujeme len v 2D podobe.

Vizualizácia 2D časopriestorovej kocky (obr. 2) odhalila rozdielne priestorové trendy aktivity počas pracovných dní. Vzostupné trendy (červené mriežky) sa koncentrujú najmä v západnej časti mesta, pričom ich priestorové rozšírenie smeruje k južným zónam. Tieto oblasti zaznamenávajú rastúcu frekvenciu výskytu záznamov a môžu predstavovať lokality s narastajúcou úlohou v každodenných presunoch používateľa.

Klesajúce trendy (modré mriežky) boli identifikované predovšetkým v centrálnej a severnej časti mesta, čo naznačuje pokles aktivity, prípadne zmenu správania, napríklad úpravu trasy alebo zníženie frekvencie návštev. Sivé mriežky predstavujú lokality bez významného trendu a zahŕňajú miesta s nízkou frekvenciou záznamov alebo miesta s trvalo vysokou aktivitou, kde sa intenzita pohybu počas obdobia výrazne nemenila. Môže ísť napríklad o miesta bydliska alebo práce.

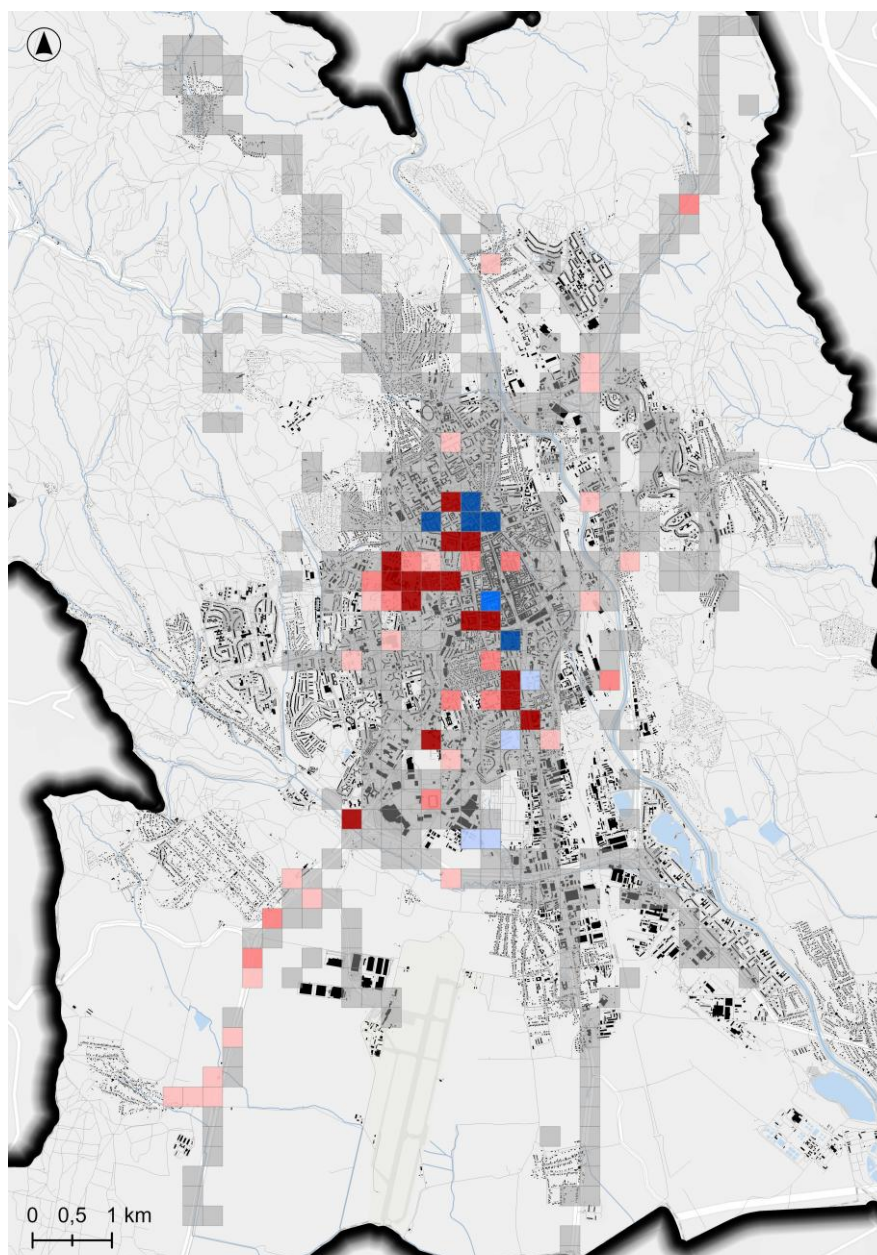
Je dôležité zdôrazniť, že medzi lokalitami so vzostupným a klesajúcim trendom nie je predpokladaná priama príčinná väzba. Nárast aktivity v jednej lokalite neznamená nevyhnutne pokles v inej. Výsledky trendovej analýzy poukazujú na dynamiku individuálnej mobility, pričom interpretácia jej príčin si vyžaduje doplnkové metódy, v tomto prípade nami zvolené časové klastrovanie (TSC).

V rámci tejto analýzy boli pre každú priestorovú mriežku vypočítané štatistické ukazovatele z-skóre a p-hodnota, ktoré vyjadrujú intenzitu a spoľahlivosť identifikovaného trendu. Hodnota z-skóre udáva smer a mieru odchýlky pozorovaného javu od priemeru. Kladné hodnoty indikujú rastúci trend, záporné hodnoty klesajúci trend, pričom čím je absolútna hodnota vyššia, tým je zmena výraznejšia. P-hodnota vyjadruje pravdepodobnosť, že zistený trend vznikol náhodne. Čím je hodnota bližšia nule, tým je štatistická významnosť vyššia.

2.1 Výsledky metód časopriestorového zhlukovania

Metóda TSC umožňuje analyzovať zmeny vo výskyte bodov v čase pre jednotlivé priestorové jednotky (mriežky) a následne ich zoskupovať podľa podobnosti časových priebehov. Ak používateľ neurčí počet klastrov vopred, algoritmus ho vypočíta automaticky. Nástroj postupne testuje rôzne počty klastrov a pre každý počet opakovane vykoná proces klastrovania s náhodnými počiatočnými hodnotami. Následne sa pre všetky varianty vypočíta pseudo-F štatistika, ktorá predstavuje pomer medzi rozptylom medzi klastrami a vnútri klastrov (tab. 2). Vyššia hodnota pseudo-F indikuje efektívnejšie rozdelenie dát, teda väčšiu vnútornú homogenitu časových sérií v rámci jedného klastra a zároveň väčšie rozdiely medzi jednotlivými klastrami. Na základe týchto výpočtov sa automaticky zvolí optimálny počet klastrov, ktorý najlepšie vystihuje štruktúru dát.

V tomto prípade boli testované modely s rôznym počtom klastrov, pričom najvyššia hodnota pseudo-F štatistiky bola dosiahnutá pri štyroch klastrach (tab. 2). To potvrdzuje, že práve toto rozdelenie najlepšie vystihuje vnútornú homogenitu časových sérií v rámci jednotlivých skupín.



— vodné toky — cestná sieť vodné plochy budovy Košice

Trend vývoja zaznamenatej aktivity

Triedy vyjadrujú smer (rast/pokles) a štatistickú významnosť trendu počtu zaznamenaných polohových bodov v jednotlivých priestorových bunkách v čase. Uvedené percentá predstavujú hladinu spoľahlivosti odhadu trendu.



Obr. 2 2D časopriestorová kocka používateľa pre pracovné dni (2022 – 2024)

Tab. 2 Hodnoty Pseudo-F TSC (Value) pre rôzne počty klastrov

počet klastrov	hodnota Pseudo-F
2	3073,511
3	5404,468
4	5431,929
5	4769,509
6	4307,941
7	3765,915
8	3505,414
9	3330,350
10	3029,685

Identifikované klastre predstavujú lokality s podobným časovým profilom aktivity a nevyjadrujú priamo funkčný charakter miest. Ich interpretácia (napr. ako potenciálne bydlisko či pracovisko) je preto založená na nepriamych indikáciách vyplývajúcich z časových vzorcov správania.

V analyzovanom prípade bol ako optimálny určený počet štyroch klastrov, ktoré reprezentujú odlišné typy časových priebehov zaznamenananej aktivity počas pracovných dní (obr. 3). Každý klastre zodpovedá skupine mriežok s podobnou dynamikou počtu záznamov v čase. Ich priestorové rozloženie je zobrazené v mape, pričom každý klastre je doplnený o reprezentatívny graf znázorňujúci priemerný denný priebeh aktivít.

Výsledky klasifikácie pomocou metódy TSC so zvoleným parametrom *value* odhaľujú výrazný časopriestorový vzorec pohybu charakteristický pravdepodobne pre dochádzku do zamestnania. V rámci identifikovaných klastrov sa zreteľne ukazujú dve dominantné lokality – klastre č. 2 (červená farba) a klastre č. 4 (oranžová farba). Na základe ich časového priebehu a počtu záznamov možno predpokladať, že ide o potenciálne miesta bydliska a zamestnania. Tieto dve lokality patria do rozdielnych klastrov s rozdielnym denným rytmom aktivít, čo poukazuje na typickú dichotómiu medzi rannými a popoludňajšími záznamami. Metóda TSC sleduje len vývoj počtu bodov v čase pre každú mriežku, a práve preto miesta s pravidelným, opakujúcim sa časovým profilom (ako domov či pracovisko) prirodzene vyniknú a zoskupia sa do samostatných tried.

Súhrnné štatistiky identifikovaných klastrov (tab. 3) poskytujú kvantitatívny prehľad o priebehu trendov v rámci jednotlivých časových sérií. Klastre 2, interpretovaný ako lokalita zamestnania, nevykazuje počas sledovaného obdobia štatisticky významný trend ($p = 0,6402$), čo znamená, že na základe použitého testu nebol preukázaný systematický monotónny vývoj v čase.

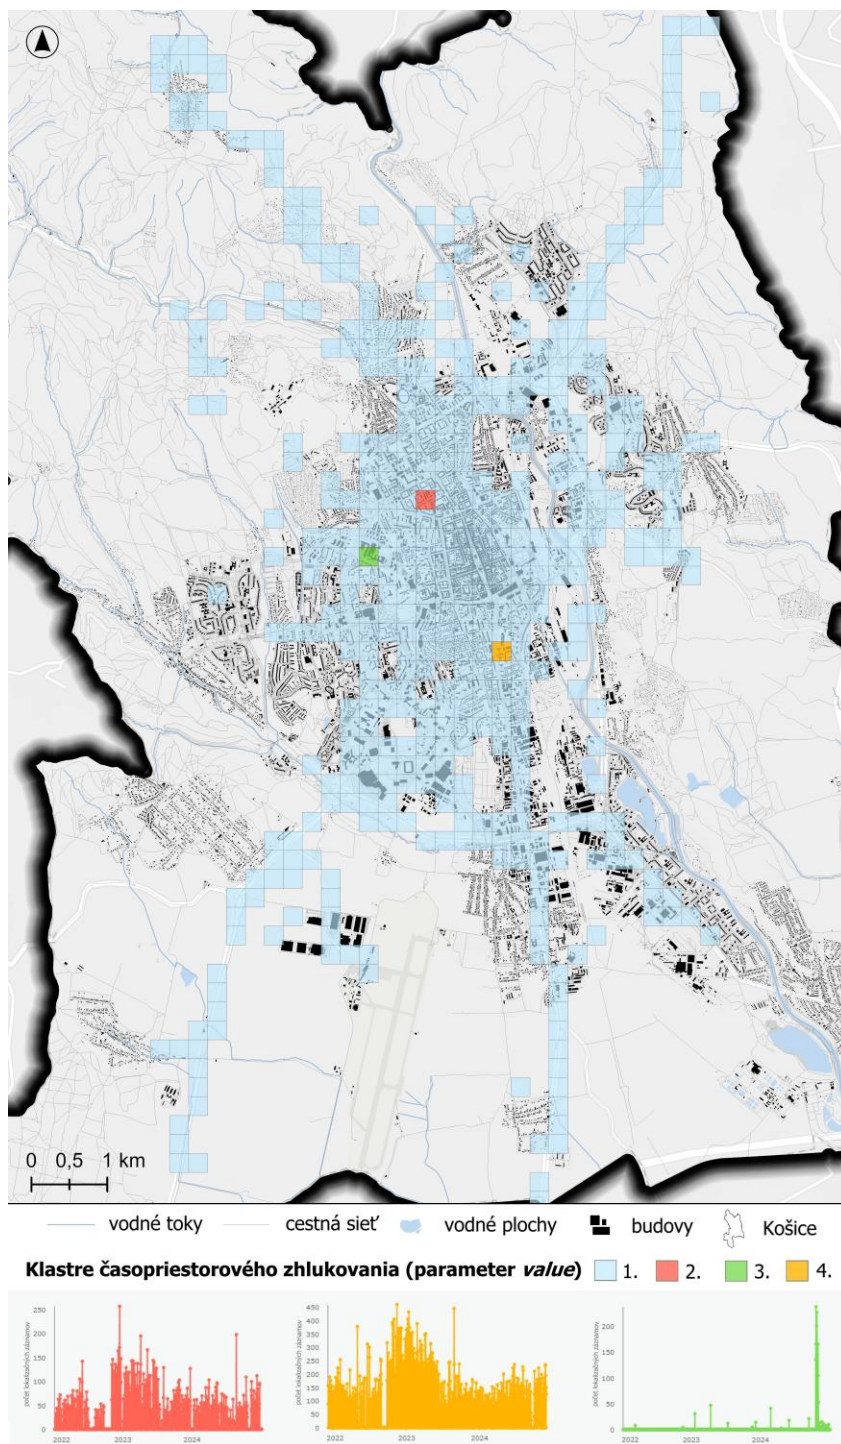
Klastre 4, reprezentujúci lokalitu bydliska, vykazuje hodnotu $p = 0,0535$, ktorá sa nachádza blízko hranice štatistickej významnosti, avšak z formálneho hľadiska ide stále o štatisticky nevýznamný výsledok. Tento výsledok možno interpretovať nanajvýš ako náznak možného trendu, ktorý by si vyžadoval ďalšie overenie na rozsiahlejších dátach.

Je zároveň potrebné zdôrazniť, že Mann–Kendallov test hodnotí monotónny trend celej časovej série, a preto z jeho výsledkov nemožno priamo odvodiť zmeny aktivity v konkrétnych častiach dňa.

Mriežky patriace do klastrov 1 a 3 majú odlišné, menej pravidelné časové profily, ktoré sa významne líšia od denných rytmov typických pre klastre 2 a 4.

Celkový výstup potvrdzuje, že časovo orientovaná klasifikácia prostredníctvom TSC metódy má značný potenciál pri identifikácii individuálnych dochádzkových vzorcov a ich zmien v čase. Ak sú k dispozícii údaje s presným časovým a priestorovým označením, metóda umožňuje detailnú interpretáciu každodenných rytmov pohybu a poskytuje komplexný pohľad na priestorovo-časovú organizáciu priestorového pohybu používateľa.

Pri interpretácii výsledkov je potrebné zohľadniť, že analýza vychádza z počtu zaznamenaných polohových bodov. Mann–Kendallov test tak hodnotí trend počtu záznamov v čase, ktorý nemusí priamo odrážať intenzitu mobility používateľa, keďže môže byť ovplyvnený aj technickými faktormi (napr. presnosť GPS či frekvencia záznamu). Identifikované trendy je preto vhodné chápať skôr ako zmeny v počte zaznamenaných polôh než ako jednoznačný dôkaz zmien v mobilnom správaní.



Obr. 3 TSC (*Value*) pre pracovné dni (2022 – 2024)

Tab. 3 Štatistiky TSC (Value) pre identifikované klastre

klaster ID	trend vývoja	trendová štatistika (Mann-Kendall)	p-hodnota
1	stúpajúci	1,9909	0,0465
2	štatisticky nevýznamný	-0,4675	0,6402
3	stúpajúci	5,8414	0,0000
4	klesajúci	-1,9310	0,0535

Druhý prístup v rámci metódy TSC využíva ako mieru podobnosti koreláciu medzi časovými priebehmi. Parameter *correlation* sa zameriava na tvar časovej série, teda na to, ako sa aktivita v čase mení, bez ohľadu na jej celkovú intenzitu. Tento prístup je vhodný najmä pri výskume oblastí, kde je cieľom identifikovať podobný rytmus denného správania (napr. pravidelná dochádzka do práce), aj keď počet záznamov sa môže medzi lokalitami líšiť.

V analyzovanom prípade metóda TSC s nastavením *correlation* odhalila dva klastre (hodnota pseudo-F pri počte klastrov 2 = 51,303), pričom každý reprezentuje skupinu mriežok s podobným denným priebehom pohybu (obr. 4). Klaster 2 (červená farba) zachytáva súvislé pásy mriežok, ktoré kopírujú hlavné dopravné tepny smerom z alebo do mesta. Zreteľne vystupuje aj pás mriežok v centrálnej časti mesta, ktorý s veľkou pravdepodobnosťou zodpovedá trase, ktorou používateľ pravidelne dochádza do zamestnania. Klaster 1 (modrá farba) pokrýva ostatné mriežky, v ktorých sa používateľ pohyboval nepravidelne alebo mimo hlavnej trajektórie dochádzky, pričom priebeh aktivít v čase sa odlišuje od dominantného denného vzorca.


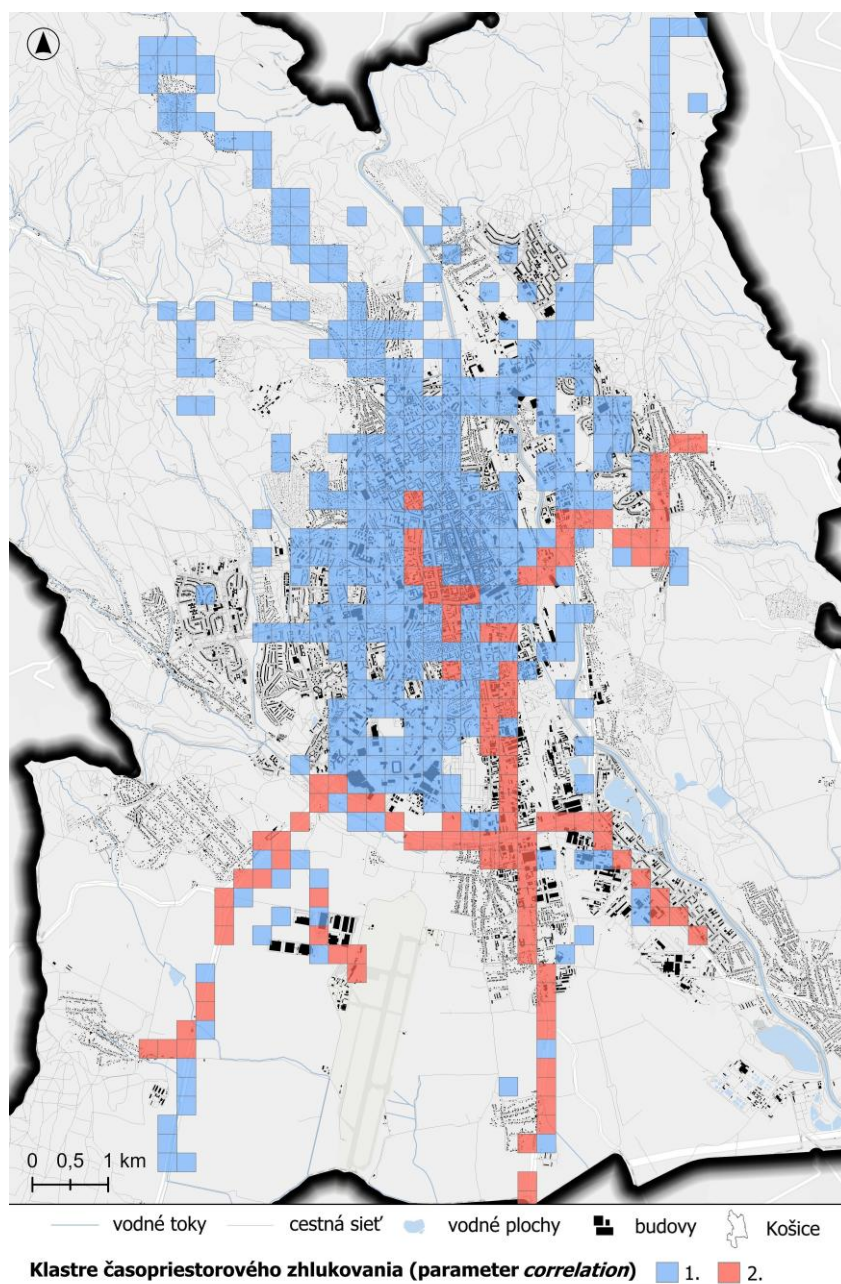
Z časového hľadiska neboli v žiadnom z klastrov identifikované štatisticky významné trendy (tab. 4). Klaster 1 vykazoval trendový koeficient -0,3145 s p-hodnotou 0,7532 a klaster 2 koeficient 0,2051 s p-hodnotou 0,8375. Obe p-hodnoty vysoko presahujú hranicu štatistickej významnosti ($p > 0,05$), čo znamená, že počas analyzovaného obdobia nedochádza k systematickému nárastu ani poklesu aktivity v týchto oblastiach.

Táto skutočnosť je v súlade s charakterom korelačného prístupu, ktorého cieľom nie je sledovať intenzitu alebo trend pohybu, ale zoskupovať oblasti s podobným časovým priebehom lokalizačných záznamov. Výsledky preto odhaľujú stabilné a opakujúce sa vzorce pohybu, najmä trasy medzi potenciálnym bydliskom a pracoviskom, ktoré síce nevykazujú trend, ale vyznačujú sa vysokou pravidelnosťou a rytmom v priebehu dňa. Takto zvolený prístup umožňuje identifikovať jadrové trasy každodennej mobility a vizuálne ich odlišiť od menej pravidelných pohybov v rámci mesta.

Spravidelné grafy dopĺňajú priestorový výstup a znázorňujú typický časový priebeh aktivity a počtu záznamov pre jednotlivé klastre. V modrom grafe (klaster 1) sa prejavuje nepravidelný časový priebeh s viacerými izolovanými vrcholmi, čo poukazuje na občasný pohyb mimo hlavnej dochádzkovej trasy. Naopak, červený graf (klaster 2) vykazuje stabilnejší priebeh s opakujúcimi sa dennými maximami, ktoré odrážajú pravidelný rytmus dochádzky medzi bydliskom a pracoviskom.

Fourierov variant metódy TSC umožňuje identifikovať oblasti, ktorých časové rady vykazujú podobné periodické vzorce v priebehu času. Metóda využíva princípy funkčnej dátovej analýzy, pri ktorej je každý časový rad rozložený na súbor základných harmonických funkcií (sínusoid a kosínusoid). Každá z týchto funkcií reprezentuje dominantný cyklický signál v dátach, napríklad denné alebo týždenné opakovanie správania. Dva časové rady sa považujú za podobné, ak majú rovnaké dominantné oscilácie (teda podobný rytmus alebo periodicitu), aj keď sa ich amplitúda alebo presný časový začiatok líši.

Aplikácia Fourierovej analýzy s periódou 1 deň umožnila identifikovať priestorové vzorce s výrazným denným cyklom aktivity, typickým pre dochádzkové správanie. Metóda identifikovala dva klastre (pseudo-F = 22,667). V analyzovanom prípade sa tento denný rytmus najvýraznejšie prejavil v podobe úzkeho koridoru medzi dvomi potenciálnymi lokalitami – bydliskom a pracoviskom používateľa (obr. 5). Tento koridor, vizuálne zvýraznený červenými bunkami, reprezentuje oblasti, v ktorých sa opakovane detegovali trajektórie pohybu s výraznou periodicitou na úrovni jedného dňa, teda s pravidelným denným opakovaním dochádzky.



Obr. 4 TSC (*Correlation*) pre pracovné dni (2022 – 2024)

Tab. 4 Štatistiky TSC (Correlation) pre identifikované klastre

klaster ID	trend vývoja	trendová štatistika (Mann-Kendall)	p-hodnota
1	štatisticky nevýznamný	-0,3145	0,7532
2	štatisticky nevýznamný	0,2051	0,8375

Štatistické hodnotenie trendu pre tieto bunky odhalilo mierny klesajúci trend frekvencie pohybov v priebehu sledovaného obdobia (z-skóre = -1,6585; p = 0,0972) (tab. 5). Hoci tento výsledok nedosahuje hranicu štatistickej významnosti, môže naznačovať postupné zníženie frekvencie fyzických presunov do pracoviska, napríklad v dôsledku využívania práce z domu či príležitostnej neprítomnosti na pracovisku. Vzhľadom na úroveň štatistickej neistoty je však potrebné interpretovať tento vývoj s istou opatrnosťou.

Naopak, zvyšok územia (modré bunky) vykazuje štatisticky významný rastúci trend aktivity (z-skóre = 2,3294; p = 0,0198), čo naznačuje nárast frekvencie lokalizačných záznamov v týchto častiach mesta počas analyzovaného obdobia. Tento trend však nereprezentuje potenciálne dochádzkové správanie, ale skôr všeobecný nárast priestorovej aktivity mimo hlavného dochádzkového koridoru, pravdepodobne súvisiaci s voľnočasovým pohybom, nákupmi alebo inými formami každodennej mobility.

Výsledky Fourierovej analýzy tak dopĺňajú predchádzajúce prístupy metódy TSC tým, že potvrdzujú existenciu stabilného denného cyklu v úzkom priestore medzi dvomi kľúčovými lokalitami, pričom zároveň poukazujú na rôznorodé trendy v iných častiach mesta, kde dochádza k mierne odlišnému vývoju časovej intenzity pohybu.

2.2 Zhodnotenie metód časopriestorového zhľukovania

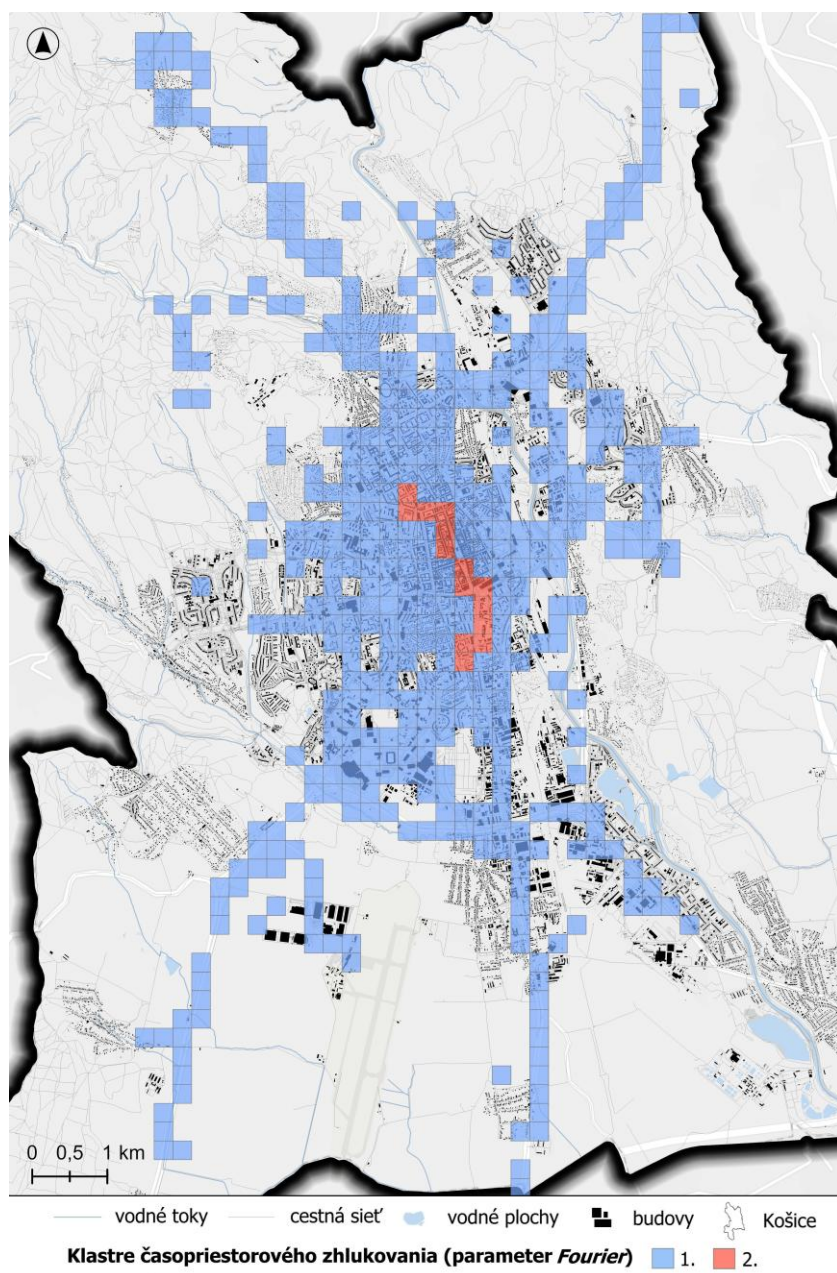
Využitie časopriestorových analytických metód v prostredí ArcGIS Pro sa ukázalo ako efektívny prístup na identifikáciu priestorových aj časových vzorcov individuálnej mobility v mestskom prostredí. Každá z metód poskytuje odlišný pohľad na dáta a umožňuje zachytiť iný aspekt priestorového správania používateľa.

2D časopriestorová kocka umožňuje kvantifikovať smer vývoja sledovaného javu v jednotlivých lokalitách a v čase. Pomocou štatistickej analýzy trendov odhaľuje oblasti, kde dochádza k dlhodobému nárastu alebo poklesu intenzity lokalizačných záznamov. Je preto vhodná na identifikáciu stabilných zmien v priestorovom správaní používateľa alebo zmeny priestorovej distribúcie dochádzky. Výhodou je jasné a jednoznačné vizuálne vyjadrenie trendov, ktoré sú ľahko interpretovateľné. Limitom však zostáva, že metóda sa sústreďuje na vývoj objemu záznamov, nezachytáva komplexnejšie vzorce správania a neumožňuje priamu interpretáciu štruktúry pohybu v priestore.

Naopak, časové klastrovanie (TSC) umožňuje analyzovať dynamiku pohybu na základe podobnosti časových radov v jednotlivých priestorových jednotkách. Pri použití parametra *value* sa porovnávajú absolútne hodnoty časových radov, čo umožňuje identifikovať oblasti s podobnou intenzitou mobility a vývojom v čase. Výsledné klastre tak vystihujú rozdiely medzi vysoko a nízko frekventovanými lokalitami, pričom analýza je vhodná na detekciu priestorových kontrastov.

Druhý variant, TSC s parametrom *correlation*, porovnáva tvar časových radov nezávisle od ich absolútnych hodnôt pomocou Pearsonovej korelácie. Zameriava sa teda na podobnosť priebehu v čase a odhaľuje oblasti s rovnakým rytmom správania bez ohľadu na počet záznamov. Ide o účinný nástroj na zachytenie priestorovej štruktúry správania, napríklad pravidelnej dochádzky, víkendovej aktivity, či periodických presunov. Slabinou tejto metódy je, že môže do rovnakého klastru zaradiť aj menej významné lokality s malým počtom záznamov, ak vykazujú podobný trend.

Fourierova časová klasifikácia rozkladá časové rady pomocou Fourierovej transformácie na základné frekvencie a porovnáva ich v čase. Zachytáva teda cyklické, periodické vzorce pohybu bez ohľadu na časové posuny alebo absolútne objemy. Táto metóda je výborná na odhalenie periodických vzorcov priestorového pohybu, napríklad procesu dochádzky do zamestnania. Dokáže odstrániť nerovnomernosti v časoch a je vhodná na identifikáciu typov správania používateľa. Na druhej strane si vyžaduje značnú mieru opatrnosti a pozornosti pri interpretácii, keďže môže igno-



Obr. 5 TSC (*Fourier*) pre pracovné dni (2022 – 2024)

rovať špecifické anomálie alebo neočakávané vzorce, ktoré nemajú periodický charakter. V kombinácii s predošlými nástrojmi Fourierova analýza dopĺňa komplexný obraz o časovej dynamike a periodických rytmoch v dátach.

Tab. 5 Štatistiky TSC (Fourier) pre identifikované klastre

klaster ID	trend vývoja	trendová štatistika (Mann-Kendall)	p-hodnota
1	stúpajúci	2,3294	0,0198
2	klesajúci	-1,6585	0,0972

3. Diskusia

Dáta zo služby GLH poskytujú detailný pohľad na časopriestorové vzorce individuálnej mobility. Aj keď analýza v tejto štúdií vychádzala z údajov jednej osoby, identifikované trajektórie medzi domovom a pracoviskom korešpondujú so zisteniami o pravidelnosti a priestorovej koncentrácii ľudského pohybu, ako uvádzajú González et al. (2008), ktorí preukázali, že väčšina ľudských presunov prebieha medzi niekoľkými stabilnými lokalitami a je výrazne predvídateľná.

Tento zdroj údajov predstavuje jedinečný spôsob, ako zachytiť individuálnu mobilitu v dlhodobom horizonte s vysokým priestorovým rozlíšením. Ruaktanonchai et al. (2018) zdôrazňujú, že tieto dáta môžu spoľahlivo nahradiť údaje zo zariadení GPS, ktoré sú obmedzené krátkym obdobím zberu. Výsledky tejto štúdie naznačujú, že takéto dáta sú vhodné aj pre aplikáciu pokročilých časopriestorových metód. Tieto prístupy umožnili odhaliť opakujúce sa rytmy pohybu a stabilitu pohybových vzorcov počas dlhého obdobia, čo by pri tradičných krátkodobých GPS meraniach nebolo možné zachytiť. V súlade s Ruaktanonchai et al. (2018) možno konštatovať, že GLH dáta nielen prekonávajú časové limity iných zdrojov, ale poskytujú aj robustný základ pre behaviorálnu interpretáciu individuálnych trajektórií pohybu. Toto tvrdenie podporuje aj zistenie Pászta et al. (2021), ktorí uvádzajú, že GLH dáta sú zbierané len so súhlasom používateľa a vďaka kombinácii lokalizačných technológií (GPS, Wi-Fi) poskytujú výrazne presnejší obraz o tom, akým spôsobom sa jednotlivci pohybujú, či zotrávajú na mieste a aká je presnosť ich polohy. Ich vysoké časové rozlíšenie navyše umožňuje skúmať variácie priestorovej mobility počas jednotlivých dní či ročných období, čím sa otvára možnosť analyzovať vplyv počasia alebo sezónnych zmien na mobilitu v mestskom prostredí. Táto vlastnosť môže predstavovať pridanú hodnotu aj pri výskume prehrievania miest a vplyvu mestských ostrovov tepla na obyvateľstvo.

Priestorová koncentrácia zaznamenaného pohybu v centre mesta Košice a na trasách vedúcich do rovnakých lokalít podporuje hypotézu o existencii stabilných a opakujúcich sa trajektórií, typických pre každodennú dochádzku (González et al., 2008; Schneider et al., 2013). Výrazným prínosom bolo využitie viacerých dimenzií časopriestorovej kocky, pričom klasifikácie časových radov s vybranými parametrami sa ukázali ako účinné aj bez potreby znalosti typu aktivity, čo zodpovedá behaviorálnemu prístupu k mobilite (Axhausen, 2007).

Metóda TSC sa ukázala ako efektívny nástroj pre klasifikáciu časopriestorových vzorcov mobility. Ako uvádzajú Panik et al. (2025), tvarová podobnosť časových radov umožňuje diferencovať medzi skupinami s odlišným rytmom pohybu, čo má zásadný význam pri analýze každodenných dochádzkových cyklov. Na tento aspekt nadväzuje aj výskum Hajlasz a Pei (2024), ktorí klastrovaním odhalili rozdiely v časovej predikovateľnosti pohybu medzi rôznymi typmi lokalít. V našej analýze metóda TSC v ArcGIS Pro poskytla porovnateľné výsledky, keď na základe podobnosti časových profilov umožnila presne vyčleniť dominantné lokality (pravdepodobne domov a prácu) a ich dlhodobú stabilitu v priebehu času. Potvrďuje sa tak, že TSC je vhodná pre analýzu rytmických a periodických foriem mobility, pričom výhodou je jej univerzálna aplikovateľnosť naprieč rôznymi typmi dátových zdrojov a obzvlášť pri dlhšom časovom úseku.

Metódy TSC predstavujú analytický prístup na identifikáciu rytmických a tvarovo podobných priebehov v mobilityných dátach (Aghabozorgi et al., 2015). Napriek tomu, samotné výsledné klastre neumožňujú jednoznačne určiť typ ľudskej aktivity a zachytávajú len podobnosť v časovom rytme, nie jeho sémantický význam. Preto viacerí autori upozorňujú, že interpretácia klastrov s označením domov či práca je možná len po doplnení kontextových informácií, napríklad funk-

čného využitia územia alebo údajov z dotazníkov (Furletti et al., 2013). V absencii takýchto doplnkov je vhodné interpretovať vzniknuté klastre opatrne ako skupiny lokalít s podobným rytmom návštev, nie ako presne definované typy aktivít, zvlášť pri veľkom počte respondentov a skupín dát.

Podobne aj časopriestorová kocka prináša prehľadný spôsob agregácie a vizualizácie trendov v časopriestorových dátach, no jej výsledky sú citlivé na parametre modelu, najmä veľkosť buniek a dĺžku časového intervalu. Nevhodné nastavenie týchto parametrov môže viesť k potlačeniu krátkodobých rytmov alebo naopak k zvýrazneniu šumu (Kraak, 2003; Andrienko et al., 2010). Výsledky preto treba interpretovať v kontexte metodických rozhodnutí a zvolenej mierky analýzy ako indikáciu trendov, nie ako absolútny opis dochádzkového správania.

Aj keď GLH predstavuje perspektívny a doposiaľ menej využívaný zdroj informácií o ľudskej mobilite, jeho širšie uplatnenie v odbornej literatúre je stále relatívne nové. Tieto údaje sa vo výskume objavujú až v posledných rokoch, čo znamená, že ich potenciál pri analýze priestorových vzorcov nebol doposiaľ naplno preskúmaný (Ruktanonchai, 2018). Pri analýze údajov GLH sa často upozorňuje na chyby GPS záznamov, ich nepresnosť v meraniach najmä pri zaznamenávaní údajov počas chôdze užívateľov (Macarulla Rodriguez et al., 2018). Z tohto hľadiska Cools et al. (2021) zdôrazňuje, že GLH nie sú vhodné na zaznamenávanie individuálnych trás používateľov. Tento nedostatok sme sa snažili v tomto príspevku eliminovať agregáciou a priestorovou analýzou záznamov aktivity v priestorových mriežkach s rozlíšením 250x250 m. Yu et al. (2019) vo svojej štúdii potvrdili, že GLH zachytávajú priestorovú mobilitu dobre práve vtedy, ak sú polohové záznamy agregované a analyzované vo väčších čiastkových mriežkach skúmaného územia, čo možno stotožniť aj s výsledkami našich analýz.

Na druhej strane sa na tieto dáta nazerá aj optikou ochrany osobných údajov a anonymizácie používateľov (Ritchie, 2020), čo bolo ďalšou motiváciou k zvoleniu priestorového rozlíšenia jednotlivých mriežok. Limitom tejto štúdie je skutočnosť, že analýza bola realizovaná na dátach jedného používateľa, čo neumožňuje zovšeobecňovanie zistení na širšiu populáciu. Zároveň je potrebné zohľadniť aj širšie limity dát GLH, najmä ich selektívnu dostupnosť, závislosť od používateľských nastavení a technických charakteristík záznamu, čo môže ovplyvňovať ich reprezentatívnosť a konzistentnosť v čase. Našu pozornosť sme preto presmerovali najmä na metodický potenciál dát GLH a demonštráciu možnosti pokročilých časopriestorových metód v GIS. Týmto prístupom poukazujeme na praktickú využiteľnosť zvolených metód pri identifikácii opakujúcich sa vzorcov individuálnej mobility aj v prípade obmedzenej vzorky, pričom získané výsledky je potrebné interpretovať s ohľadom na charakter dát. Výstupy tak poskytujú detailný obraz o spôsobe využívania priestoru konkrétnym používateľom, jeho pravidelnosti a zmien, a môžu byť prínosné najmä pre výskumy mikroúrovne mobility alebo ako podklad pre ďalšie metodické rozpracovanie v kontexte urbánneho výskumu (Batty, 2013).

Záver

Príspevok predstavil využitie dát GLH v prostredí GIS so zameraním na tvorbu 2D časopriestorovej kocky a následnú aplikáciu metód časopriestorového zhľukovania (*Time Series Clustering*). Metodický postup demonštruje, ako je možné pomocou tejto kombinácie nástrojov identifikovať časopriestorové vzorce pohybu a rozlíšiť územia s odlišnou dynamikou v rámci dennej urbánnej mobility. Výsledky ukázali, že 2D časopriestorová kocka poskytuje intuitívny prehľad o intenzite presunu v čase, zatiaľ čo klastrovanie časových radov umožňuje odhaliť podobnosti v dlhodobom správaní jednotlivých lokalít a jednoznačne identifikuje lokality s pravidelnosťou zaznamenaného pohybu.

Výhodou použitého prístupu je vysoké časové rozlíšenie GLH dát, ktoré podporuje detailnú analýzu variability pohybu medzi jednotlivými dňami či obdobiami roka. Limitom je však skutočnosť, že dáta reprezentujú mobilitu jednej osoby, čo obmedzuje možnosti generalizácie na populáciu. Cieľom príspevku bolo preto predovšetkým poukázať na metodický potenciál nástrojov časopriestorového zhľukovania v GIS a ich využiteľnosť pri práci s vybranými dátami, ktoré sa často v tomto kontexte neskúmajú. Príspevok tiež prináša samotné zhodnotenie využitých metód, čo predstavuje inovatívny prístup k pohľadu na GIS metódy a techniky využívané v kartografii.

Budúci výskum môže smerovať k integrácii dát od viacerých používateľov, k porovnaniu rôznych foriem priestorovej agregácie a k rozšíreniu analýzy o environmentálne premenné, ako napríklad sezónnosť alebo meteorologické podmienky.

PodĎakovanie

Príspevok vznikol za podpory projektov VEGA 1/0768/24: Multimierkové hodnotenie priestorovej variability sociálno-ekonomickej stratifikácie obyvateľstva, APVV-23-0210: Prehrievanie mesta: dôsledky, zmiernovanie a percepcia a VVGS 2026-3882: Zdieľaná mikromobilita v mestskom prostredí: priestorové a časové aspekty využívania jej dopravných prostriedkov.

Literatúra

- AGHABOZORGI, S., SHIRKHORSHIDI, A. S., WAH, T. Y. (2015). Time-series clustering – a decade review. *Information Systems*, 53, 16-38. DOI: <https://doi.org/10.1016/j.is.2015.04.007>
- ANDRIENKO, G., ANDRIENKO, N., DEMSAR, U., DRANSCH, D., DYKES, J., FABRIKANT, S. I., JERN, M., KRAAK, M.-J., SCHUMANN, H., TOMINSKI, C. (2010). Space, time and visual analytics. *International Journal of Geographical Information Science*, 24(10), 1577-1600. DOI: <https://doi.org/10.1080/13658816.2010.508043>
- ARIAS-MOLINARES, D., ROMANILLOS, G., GARCÍA-PALOMARES, J. C., GUTIÉRREZ, J. (2021). Exploring the spatio-temporal dynamics of moped-style scooter sharing services in urban areas. *Journal of Transport Geography*, 96, 103193. DOI: <https://doi.org/10.1016/j.jtrangeo.2021.103193>
- AXHAUSEN, K. W. (2007). Activity spaces, biographies, social networks and their welfare gains and externalities: some hypotheses and empirical results. *Mobilities*, 2(1), 15-36. DOI: <https://doi.org/10.1080/17450100601106203>
- BATTY, M. (2013). Big data, smart cities and city planning. *Dialogues in Human Geography*, 3(3), 274-279. DOI: <https://doi.org/10.1177/2043820613513390>
- BROWNING, C. R., SOLLER, B. (2014). Moving beyond neighborhood: Activity spaces and ecological networks as contexts for youth development. *Cityscape*, 16(1), 165-196.
- CAGNEY, K. A., BROWNING, C. R., JACKSON, A. L., SOLLER, B. (2013). Networks, neighborhoods, and institutions: An integrated 'activity space' approach to research on aging. In WAITE, L. J., PLEWES, T. L. (eds.) *New Directions in the Sociology of Aging*, 60-80. Washington, DC (National Academies Press).
- CAGNEY, K. A., YORK CORNWELL, E., GOLDMAN, A. W., CAI, L. (2020). Urban mobility and activity space. *Annual Review of Sociology*, 46(1), 623-648. DOI: <https://doi.org/10.1146/annurev-soc-121919-054848>
- CATS, O. (2024). Identifying human mobility patterns using smart card data. *Transport Reviews*, 44(1), 213-243. DOI: <https://doi.org/10.1080/01441647.2023.2251688>
- CATS, O., FERRANTI, F. (2022). Unravelling individual mobility temporal patterns using longitudinal smart card data. *Research in Transportation Business & Management*, 43, 100816. DOI: <https://doi.org/10.1016/j.rtbm.2022.100816>
- COOLS, D., MCCALLUM, S. C., RAINHAM, D., TAYLOR, N., PATTERSON, Z. (2021). Understanding Google Location History as a tool for travel diary data acquisition. *Transportation Research Record*, 2675 (5), 238-251. DOI: <https://doi.org/10.1177/0361198120986169>
- DE OLIVEIRA CAVALCANTI, C., LIMONT, M., DZIEDZIC, M., FERNANDES, V. (2017). Sustainability of urban mobility projects in the Curitiba metropolitan region. *Land Use Policy*, 60, 395-402. DOI: <https://doi.org/10.1016/j.landusepol.2016.11.015>
- ESRI (2025a). *How Create Space Time Cube works* [online]. [cit. 2025-11-5]. Dostupné na: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/space-time-pattern-mining/learnmorecreatecube.htm>
- ESRI (2025b). *How Time Series Clustering works* [online]. [cit. 2025-10-27]. Dostupné na: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/space-time-pattern-mining/learnmoretimeseriesclustering.htm>
- FURLETTI, B., CINTIA, P., RENSO, C., SPINSANTI, L. (2013). Inferring human activities from GPS tracks. In *UrbComp '13: Proceedings of the 2nd ACM SIGKDD International Workshop on Urban Computing*, Article No. 5, 1-8. DOI: <https://doi.org/10.1145/2505821.2505830>
- GÁBOR, Š., NOVOTNÝ, L., PREGI, L. (2025). Revealing spatial patterns of dockless shared micromobility: a case study of Košice, Slovakia. *Urban Science*, 9(4), 107. DOI: <https://doi.org/10.3390/urbansci9040107>

- GÁBOR, Š., PREGI, L. (2023). Spatial differentiation of daily commuting to work in Slovakia by modes of transport. *Geographia Cassoviensis*, 17(2), 150-175. DOI: <https://doi.org/10.33542/GC2023-2-04>
- GONZÁLEZ, M. C., HIDALGO, C. A., BARABÁSI, A. L. (2008). Understanding individual human mobility patterns. *Nature*, 453(7196), 779-782. DOI: <https://doi.org/10.1038/nature06958>
- HADAVI, S., VERLINDE, S., VERBEKE, W., MACHARIS, C., GUNS, T. (2018). Monitoring urban-freight transport based on GPS trajectories of heavy-goods vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 20(10), 3747-3758. DOI: <https://doi.org/10.1109/TITS.2018.2880949>
- HAJLASZ, M., PEI, S. (2024). Predictability of human mobility during the COVID-19 pandemic in the United States. *PNAS Nexus*, 3(8), pgae308. DOI: <https://doi.org/10.1093/pnasnexus/pgae308>
- HYSTAD, P., AMRAM, O., OJE, F., LARKIN, A., BOAKYE, K., AVERY, A., GEBREMEDHIN, A., DUNCAN, G. (2022). Bring your own location data: Use of Google smartphone location history data for environmental health research. *Environmental Health Perspectives*, 130(11), 117005. DOI: <https://doi.org/10.1289/EHP10829>
- JIANG, S., FERREIRA, J., GONZÁLEZ, M. C. (2012). Clustering daily patterns of human activities in the city. *Data Mining and Knowledge Discovery*, 25(3), 478-510. DOI: <https://doi.org/10.1007/s10618-012-0264-z>
- JIANG, S., FERREIRA, J., GONZÁLEZ, M. C. (2017). Activity-based human mobility patterns inferred from mobile phone data: A case study of Singapore. *IEEE Transactions on Big Data*, 3(2), 208-219. DOI: <https://doi.org/10.1109/TBDATA.2016.2631141>
- JONES, M., PEBLEY, A. R. (2014). Redefining neighborhoods using common destinations: Social characteristics of activity spaces and home census tracts compared. *Demography*, 51(3), 727-752. DOI: <https://doi.org/10.1007/s13524-014-0283-z>
- KONG, H., CHAO, H., FU, W., LIN, D., ZHANG, Y. (2025). Relationship between shared micromobility and public transit: The differences between shared bikes and shared e-bikes. *Journal of Transport Geography*, 123, 104149. DOI: <https://doi.org/10.1016/j.jtrangeo.2025.104149>
- KRAAK, M. J. (2003). The space-time cube revisited from a geovisualization perspective. In *ICC 2003: Proceedings of the 21st International Cartographic Conference – Cartographic Renaissance*, Durban, South Africa, International Cartographic Association. 1988–1996.
- LI, Q., FUERST, F., LUCA, D. (2023). Do shared e-bikes reduce urban carbon emissions? *Journal of Transport Geography*, 112, 103697. DOI: <https://doi.org/10.1016/j.jtrangeo.2023.103697>
- LÖCHTEFELD, M. (2019). Detournavigator – Using Google Location History to generate unfamiliar personal routes. In *CHI '19 Extended Abstracts of the 2019 CHI Conference on Human Factors in Computing Systems*, 1-6. DOI: <https://doi.org/10.1145/3290607.3313047>
- LUO, F., CAO, G., MULLIGAN, K., LI, X. (2016). Explore spatiotemporal and demographic characteristics of human mobility via Twitter: A case study of Chicago. *Applied Geography*, 70, 11-25. DOI: <https://doi.org/10.1016/j.apgeog.2016.03.001>
- MACARULLA RODRIGUEZ, A., TIBERIUS, C., VAN BREE, R., GERADTS, Z. (2018). Google timeline accuracy assessment and error prediction. *Forensic Sciences Research*, 3(3), 240-255. DOI: <https://doi.org/10.1080/20961790.2018.1509187>
- MAMEI, M., COLONNA, M. (2016). Estimating attendance from cellular network data. *International Journal of Geographical Information Science*, 30(7), 1281-1301. DOI: <https://doi.org/10.1080/13658816.2015.1127378>
- MIYAZAWA, S., SONG, X., XIA, T., SHIBASAKI, R., KANEDA, H. (2019). Integrating GPS trajectory and topics from Twitter stream for human mobility estimation. *Frontiers of Computer Science*, 13(3), 460-470. DOI: <https://doi.org/10.1007/s11704-017-6464-3>
- NAIT-SIDI-MOH, A., BAKHOUYA, M., GABER, J., WACK, M. (eds.) (2013). *Geopositioning and Mobility*. London (John Wiley & Sons). DOI: <https://doi.org/10.1002/9781118743751>
- PALMER, J. R. B., ESPENSHADE, T. J., BARTUMEUS, F., CHUNG, C. Y., OZGENCIL, N. E., LI, K. (2013). New approaches to human mobility: Using mobile phones for demographic research. *Demography*, 50(3), 1105-1128. DOI: <https://doi.org/10.1007/s13524-012-0175-z>
- PÁSZTO, V., BURIAN, J., MACKŮ, K. (2021). Changing mobility lifestyle: A case study on the impact of COVID-19 using personal Google Locations data. *International Journal of E-Planning Research (IJEPR)*, 10(2), 66-79. DOI: <https://doi.org/10.4018/IJEPR.20210401.oa6>
- PAZZINI, M., CAMELI, L., LANTIERI, C., VIGNALI, V., DONDI, G., JONSSON, T. (2022). New micro-mobility means of transport: An analysis of e-scooter users' behaviour in Trondheim. *International Journal of Environmental Research and Public Health*, 19(12), 7374. DOI: <https://doi.org/10.3390/ijerph19127374>

- PERIYASAMY, A. G., VENKATESH, U. (2021). Population Mobility, Lockdowns, and COVID-19 Control: An Analysis Based on Google Location Data and Doubling Time from India. *Healthcare Informatics Research*, 27(4), 325-334. DOI: <https://doi.org/10.4258/hir.2021.27.4.325>
- PREGI, L., NOVOTNÝ, L., GÁBOR, Š. (2022). Vizualizácia priestorových procesov pomocou online mapovej aplikácie Flowmap.blue. *Kartografické listy*, 30(1), 21-38.
- RITCHIE, H. (2020). COVID-19 Mobility Trends. *Oxford: Our World in Data*. [online] [cit. 2025-10-27]. Dostupné na: <https://ourworldindata.org/covid-mobility-trends>
- RODE, P., HOFFMANN, C., KANDT, J., GRAFF, A., SMITH, D. (2015). *Towards new urban mobility: The case of London and Berlin. LSE Cities*. London (London School of Economics and Political Science).
- RUKTANONCHAI, N. W., RUKTANONCHAI, C. W., FLOYD, J. R., TATEM, A. J. (2018). Using Google Location History data to quantify fine-scale human mobility. *International Journal of Health Geographics*, 17(1), 28. DOI: <https://doi.org/10.1186/s12942-018-0150-z>
- SCHNEIDER, C. M., BELIK, V., COURONNÉ, T., SMOREDA, Z., GONZÁLEZ, M. C. (2013). Unraveling daily human mobility motifs. *Journal of The Royal Society Interface*, 10(84), 20130246. DOI: <https://doi.org/10.1098/rsif.2013.0246>
- ŠVEDA, M., BARLÍK, P. (2018). Daily commuting in the Bratislava metropolitan area: Case study with mobile positioning data. *Papers in Applied Geography*, 4(4), 409-423. DOI: <https://doi.org/10.1080/23754931.2018.1540357>
- YU, X., STUART, A. L., LIU, Y., IVEY, C. E., RUSSELL, A. G., KAN, H., HENNEMAN, L. R. F., SARNAT, S. E., HASAN, S., SADMANI, A., YANG, X., YU, H. (2019). On the accuracy and potential of Google Maps location history data to characterize individual mobility for air pollution health studies. *Environmental Pollution*, 252, 924-930. DOI: <https://doi.org/10.1016/j.envpol.2019.05.081>
- ZUNIGA-GARCIA, N., JURI, N. R., PERRINE, K. A., MACHEMEHL, R. B. (2021). E-scooters in urban infrastructure: Understanding sidewalk, bike lane, and roadway usage from trajectory data. *Case Studies on Transport Policy*, 9(3), 983-994. DOI: <https://doi.org/10.1016/j.cstp.2021.04.004>

S u m m a r y

Using Google Location History Data to Explore Spatio-Temporal Patterns of Movement in Urban Areas

The empirical result of our study is the identification of spatial clusters with distinct temporal mobility patterns derived from Google Location History (GLH) data in an urban environment (Figs. 2–5). GLH represents a novel and increasingly relevant source of passively collected geospatial data, offering high spatial and temporal resolution for the analysis of individual mobility. Despite its growing availability, its application in detailed intra-urban mobility research, particularly for identifying commuting patterns, remains limited.

In this study, we used a three-year dataset (2022–2024) of anonymized location records from a single user in the city of Košice. The data were preprocessed in the R environment and subsequently transformed into a regular spatial grid (250 × 250 m), enabling their integration into a GIS-based analytical framework. A 2D Space-Time Cube was constructed to aggregate spatiotemporal events into structured units, preserving both spatial distribution and temporal dynamics of recorded activity.

To analyze temporal patterns, we applied the Time Series Clustering (TSC) method implemented in ArcGIS Pro. Three different similarity approaches were used: value-based similarity, profile correlation, and Fourier transformation. Each approach captures a different aspect of temporal behaviour – absolute intensity, shape of temporal evolution, and periodicity, respectively. The results demonstrate that these complementary methods allow for a nuanced interpretation of mobility patterns and reveal different dimensions of spatiotemporal organization.

The analysis identified several distinct spatial clusters corresponding to different types of daily activity. In particular, two dominant clusters were interpreted as probable home and workplace locations based on their contrasting temporal signatures. The value-based clustering highlighted differences in activity intensity, while the correlation-based approach revealed stable commuting routes characterized by consistent daily rhythms. The Fourier-based method further confirmed the presence of strong periodic patterns, particularly daily cycles associated with regular commuting behaviour.

Our findings demonstrate that GLH data can effectively capture long-term stability and periodicity in individual mobility patterns. Compared to traditional short-term GPS tracking or survey-based approaches, GLH provides a more continuous and detailed representation of everyday movement. The integration of these data with advanced spatiotemporal analytical methods enables the identification of functional urban areas and recurring behavioural patterns without requiring explicit information about activity types.

At the same time, several limitations must be acknowledged. The study is based on data from a single user, which limits the generalizability of the results. Furthermore, the analysis relies on the number of recorded location points, which may be influenced by technical factors such as signal accuracy or device settings. Therefore, the identified patterns should be interpreted as indicators of recorded activity rather than exact measures of mobility intensity.

Despite these limitations, the study provides a methodological contribution by demonstrating the applicability of GLH data in combination with Space-Time Cube and TSC techniques for urban mobility research. The approach offers a scalable framework that can be extended to larger datasets and different urban contexts.

Future research should focus on incorporating data from multiple users, comparing different spatial aggregation strategies, and integrating additional contextual variables, such as environmental conditions or land-use data. Such extensions would further enhance the analytical potential of GLH data and contribute to a deeper understanding of spatiotemporal dynamics in urban systems.

Fig. 1 Example of Data Processing Code in RStudio

Fig. 2 2D Space-Time Cube of the User for Weekdays (2022–2024)

Fig. 3 TSC (*Value*) for Weekdays (2022–2024)

Fig. 4 TSC (*Correlation*) for Weekdays (2022–2024)

Fig. 5 TSC (*Fourier*) for Weekdays (2022–2024)

Tab. 1 Final Dataset Structure for the Analysis of Spatiotemporal Patterns

Tab. 2 Pseudo-F Values for TSC (*Value*) Across Different Numbers of Clusters

Tab. 3 TSC (*Value*) Statistics for Identified Clusters

Tab. 4 TSC (*Correlation*) Statistics for Identified Clusters

Tab. 5 TSC (*Fourier*) Statistics for Identified Clusters

Prijaté do redakcie: 20. novembra 2025

Zaradené do tlače: jún 2026