

Váczai, Sándor<sup>1</sup> – Fabula, Szabolcs<sup>2</sup> – Nagy, Gábor<sup>3</sup>

# A big data szerepe a városi mobilitás kutatásában és fejlesztésében

The role of big data in urban mobility research and development

## ABSZTRAKT

A big data alkalmazása dinamikusan növekszik a városi mobilitás kutatásában, de viszonylag kevés olyan tanulmány létezik, amelyben a szerzők szisztematikusan áttekintik az eddigi eredményeket ezen a területen. Célunk ezért az, hogy feltárjuk, milyen általános jellemzői vannak a big data használatának a városi mobilitás tudományos vizsgálatában. E cél elérése érdekében a szisztematikus szakirodalmi áttekintés módszerét alkalmaztuk, amihez a Scopus tudományos bibliográfiai adatbázisból gyűjtöttük össze az előre meghatározott kritériumoknak megfelelő, releváns közleményeket. Az így kialakított mintába bekerült közleményeket kvantitatív és kvalitatív technikákkal elemeztük, különös tekintettel az adatbázisunkban lévő publikációk megjelenési éveiből kirajzolódó trendekre, a tanulmányok folyóiratok szerinti megoszlására, a bennük szereplő mintaterületek földrajzi megoszlására, továbbá a tanulmányokban alkalmazott módszerekre és adattípusokra, valamint szakpolitikai vonatkozásaira. Az eredmények alapján feltárul a big data megközelítésű városi mobilitáskutatás sokszínűsége, ami számos tanulsággal szolgálhat a magyarországi földrajzkutatás és várospolitiká számára is.

*Kulcsszavak: térbeli mobilitás, mikromobilitás, aktivitási mintázat, Scopus*

## ABSTRACT

The use of big data in urban mobility research is growing dynamically. However, relatively few studies have been devoted to systematically review the results in this field. Therefore, the aim of the present study is to explore the general characteristics of the application of the big data approach in urban mobility research. For this purpose, the systematic literature review method was applied and the scientific Scopus database was accessed to collect publications relevant to the predefined criteria. Then the papers included in the sample were analysed using quantitative and qualitative techniques, focusing on the trends emerging from the years of publications in the database, the distribution of the papers by journal, the geographical distribution of case-study areas, the methods and data types employed, and their policy implications. This literature review demonstrates the diversity of big data-driven urban mobility research and provides lessons for geography and urban policy in Hungary.

*Keywords: spatial mobility, micromobility, activity pattern, Scopus*

<sup>1</sup> Geographer, University of Szeged, Faculty of Science and Informatics, +36301804346, geo.vaczi.sandor@gmail.com

<sup>2</sup> Assistant professor, University of Szeged, Faculty of Science and Informatics, Department of Economic and Social Geography, Szeged, Egyetem utca 2. +36306127686, Fabula.Szabolcs@geo.u-szeged.hu, orcid: 0000-0001-7152-8409, corresponding author

<sup>3</sup> Associate professor, Centre for Economic and Regional Studies, Eötvös Loránd Research Network, 5600 Békéscsaba, Szabó D. u. 40–42. +3666441-801, orcid: 0000-0002-9012-0676, nagy.gabor@krtk.hu

## BEVEZETÉS

Tanulmányunkban a big data és a városi mobilitás kutatásának kapcsolatát vizsgáljuk. A big data egy széles körben alkalmazott technológia a városkutatáson belül, és növekvő jelentőségét mutatja, hogy egyre többféle téma kapcsán használják, így például a városi mobilitás kutatásában is. A városkutatásban és -tervezésben ugyanis egyre nagyobb kihívást jelent a megbízható adatok rendelkezésre állása. Az emberi mobilitásra vonatkozó adatokat korábban terepi felmérésekkel gyűjtötték, azonban az ilyen felmérések költségesek, időigényesek voltak, és egy adott mintaterületre általában csak évente egyszer – vagy ritkábban – végezték el őket. Emellett gyakran önbevalláson alapultak, ami negatív hatással lehet az így gyűjtött adatok megbízhatóságára és hitelességére. Többek között a terepközeli módszerekkel gyűjtött adatok ilyen jellegű korlátai miatt fordulnak a kutatók egyre gyakrabban a big data felé. A big data-módszerek ugyanis gyakran jobb elérhetőséget biztosítanak, és valós idejű vizsgálatokat is lehetővé tesznek (Melikov et al., 2021). Az elmúlt évtizedben számos tanulmány született, amelyekben a városi mobilitás különböző aspektusait big data alkalmazásával vizsgálták (Gan et al., 2018; Melikov et al., 2021; Yuan et al., 2012; Zeinab et al., 2020).

A big datát alkalmazó kutatások köre tehát dinamikusan bővül, aminek egyik következménye az, hogy sokan sokféleképpen értelmezik magát a fogalmat, és számos módon vizsgálják az ahhoz kapcsolódó jelenségeket. Mindez nemcsak a big data alkalmazásában úttörő üzleti szférát érinti, hanem az egyes tudományterületekre és a különböző (szak)politikákra vonatkozóan is igaz. Az Európai Unióban (EU) például igen nagy figyelmet fordítanak a digitalizációra, amit a Covid19-járványhelyzet okozta kihívások is ösztönöztek. Az Európa 2020 (Europe 2020) stratégia az intelligens, inkluzív és fenntartható növekedést célozta meg, melynek részét képezi az innovatív és fenntartható európai közlekedési rendszer megalkotása, nagy hangsúlyt fektetve a közlekedés városi dimenziójára. A fenti témában meghozott szakpolitikai intézkedéseknek pedig illeszkedniük kell a fenntartható város koncepciójába is (Kukely et al., 2017). A digitalizáció és a városi mobilitás kapcsolata a jelenlegi (2021–2027-es) EU-s programozási ciklusban várhatóan tovább erősödik. Az EU 2021-ben határozta meg a digitális átalakulás négy fő irányát, a „digitális iránytűt” – készségek, kormányzat, infrastruktúra, vállalkozások –, amely a következő évtizedre meghatározza a digitalizációs stratégia irányát (Demertzis, 2021). A 2021–2027-re vonatkozó fő EU-s fejlesztési célok közül több – Intelligensebb Európa, Zöldebb Európa, Összekapcsoltabb Európa – is érinti a digitalizáció és az erőforrás-hatékonyabb mobilitás kérdéskörét [1]. Ugyanakkor a városi közlekedés olyan szakpolitikákban is megjelenik, mint például az új mobilitási keretrendszer (Urban Mobility Framework), amelynek egyik pillére a fenntartható városi mobilitás érdekében az áramlások hatékonyabb kezelése multimodális csomópontok és digitális megoldások révén [2]. A fent leírt dinamikus bővülés könnyen fogalmi és tematikai ellentmondásokhoz vezethet, ezért hasznosak lehetnek a big datával kapcsolatos rendszerező, szakirodalmi áttekintő tanulmányok.

Tanulmányunk szempontjából különösen fontos, hogy mindenekelőtt meghatározzuk az általunk választott téma fogalmi kereteit. A big data az egyik gyakori meghatározás szerint nagy mennyiségű,

gyors keletkezésű, sokféle adat összessége, amelynek hasznosításához sajátos technológiára és elemzési módszerekre van szükség. A big data-jellegű adatoknak nincs általános mérete, így e tekintetben azok egymástól jelentősen eltérők lehetnek. Jellemzően tera- és petabyte-okban mérik a különböző éghajlati adatokat, gigabyte-okban a különféle társadalmi hálózatok adatait, ugyanakkor a már tisztított és strukturált adatok gyakran megabyte méretűek. A big data azért is tekinthető innovatív technológiának, mert az adatgyűjtés, -rendszerezés, -tárolás, -megosztás és -elemzés új módjaira, ezzel együtt pedig a természeti és társadalmi jelenségek újszerű vizsgálatára nyújt lehetőséget (Ságvári, 2017). A big data legfontosabb ismérveit 3V-ként szokták összefoglalni a három legjellemzőbb tulajdonsága alapján: volume, variety, velocity<sup>4</sup>. Ez a meghatározás Doug Laney nevéhez köthető, aki 2001-ben írta le a big data-adatkezelés három dimenzióját. Azonban a fenti három tényezőt később további jellemzőkkel egészítették ki, így jelenleg a big data alapvető tulajdonságai az alábbiak (Patgiri & Ahmed, 2016):

- Nagy méret: a big data legfontosabb jellemzője, amely az adathalmaz nagyságára vonatkozik, és gyakran több terrabyte-nyi méretet jelent.
- Változatosság: a különböző adatforrások sokszínűségét jelenti, mivel az adatok többféle forrásból származhatnak.
- Nagy sebesség: az adatok valós időben vagy valóshoz közeli időben keletkeznek.
- Relációs jelleg: az egyes adatbázisok vagy adattáblák olyan közös mezőket tartalmaznak, amelyek használatával össze lehet azokat kapcsolni. Bár érdemes megjegyezni, hogy igen gyorsan terjednek a nem relációs adatmodellek is, mivel ezek a hagyományos adatbázis-rendszerekre jellemző táblázatos (sorokba és oszlopokba rendezett) séma helyett olyan tárolási modellt (pl. kulcs/érték párok, gráf) használnak, amely a tárolt adattípus sajátosságaihoz igazodik. A big data időszakában mindez előnyt jelent, mivel nemcsak nagy mennyiségű adat tárolására nyújt lehetőséget, hanem az adatbázisban való gyorsabb lekérdezésre is.
- Nagy felbontás: az adatok pontosságát jelenti; például azt, hogy a korábban alkalmazottnál kisebb területi és időbeli léptékhez (pl. mobilcellaadatoknál településen belüli, illetve napszakra vagy még kisebb időegységre vonatkozó adatok), nagy pontosságú koordinátákhoz (pl. GPS) vagy új szempontú népességcsoport-kategóriákhoz (pl. fogyasztói preferenciák, viselkedési csoportok) kapcsolható adatokról van-e szó.
- Teljesség: a népesség teljességének megragadására törekszik. Adatokkal igyekeznek lefedni a teljes népességet az adott területen, azonban ez nem lehetséges, mivel nem mindenki mobilis. A technikai elérhetőség és a tudatosság is befolyásolhatja.
- Rugalmasság: az adatok rugalmasan kezelhetők, így például az adattáblákhoz lehetőség van új mezőket hozzáadni vagy elvenni, és a méretük is módosítható (lásd még: Kitchin, 2014; Pucci & Vecchio, 2019).

Tanulmányunk másik alapfogalmának, a városi mobilitásnak a definíciója legegyszerűbben a következőképpen határozható meg: az egyének városi térben történő mozgása a kiválasztott úti céljuk elérése érdekében, amihez különböző közlekedési módokat vesznek igénybe (Vidović et al., 2019). A

<sup>4</sup> Nagy méret, nagy sebesség, változatosság.

városi mobilitás mindenki által elérhető alapegységének tekinthető a gyaloglás, emellett megjelennek különböző közlekedési eszközök, mint a kerékpár és a gépjárművek. Jelenleg egyre nagyobb szerepe van a fenntarthatóságnak a városi mobilitás területén, ami a kisebb károsanyag-kibocsátású, illetve az erőforrásokat hatékonyabban használó közlekedési módok előnyben részesítésével jár. A fenntarthatósággal kapcsolatban így különösen nagy jelentősége van a mikromobilitási eszközöknek, amelyek környezetkímélőbb közlekedési megoldást kínálnak a motorizált közlekedéshez képest. Ilyenek például az elektromos rollerek és kerékpárok (Bereczky, 2021; Jeney et al., 2014).

A továbbiakban a városi mobilitás kutatását tágan értelmezzük. Nemcsak a városi népesség mozgásjelenségeinek vagy a közlekedési rendszereknek az elemzését soroljuk ide, hanem az olyan vizsgálatokat is, amelyekben a kutatók big data alkalmazásával feltárták ugyan az emberek térbeli mobilitásának és aktivitásának egyes aspektusait, de fő céljuk valamilyen másik jelenség megértése volt. Ide tartoznak például az olyan kutatások, amelyek a városi területhasználat jellegzetességeire vagy a társadalmi-térbeli rétegződésre (foglalkoztatottsági mintázat, szegregáció, dzsentifikáció) vonatkoznak. Ugyancsak lényeges szempont, hogy a big data-jellegű adatok sokfélesége miatt mobilitáskutatás alatt azokat a tanulmányokat is értjük, amelyekben csak közvetetten mutatható ki az egyes emberek fizikai helyváltoztatása, például a közösségimédia- vagy mobilcellaadatok alapján csak a városi térben való „előfordulásukat”, jelenlétüket lehet nagy biztossággal megállapítani. Ami viszont alapvető kritérium a szempontunkból: az adott kutatás közvetlenül vagy közvetetten az emberek városi térben történő fizikai mozgásával és aktivitásával foglalkozzon, big data-adatok felhasználásával.

A nemzetközi szakirodalomban a big data használatát a városi mobilitás vizsgálatában több tanulmány is tárgyalta szakirodalmi áttekintés keretében. Témánk szempontjából lényeges, hogy egyes szerzők nagy hangsúlyt fektetnek a szakpolitikai alkalmazhatóságra, különösen olyan kérdéskörök esetében, mint a fenntarthatóság. A lehetséges okok között megemlíthető, hogy napjainkban a fenntarthatóság egyre hangsúlyosabb a városirányítási és -fejlesztési folyamatok megtervezésétől a végrehajtáson át a köztes és utólagos monitoring fázisokig. E folyamatok során pedig egyre szorosabb kapcsolat alakul ki a piaci szereplők, illetve a várostervezők és a szakpolitika között a big data alkalmazása terén. Így a politikai döntéshozók számára is lehetőség nyílik az emberek mobilitási jellemzőinek megértésére a városi térben azáltal, hogy a piaci szolgáltatók az általuk gyűjtött adatok révén követhetővé teszik a mobilitási mintázatok térbeli és időbeli változásait. A városi mikromobilitás adataalapú vizsgálata ugyanakkor elősegíti a környezetkímélő megosztásos eszközök elterjedését a városi térben azzal a céllal, hogy alternatív megoldást kínáljon a nem megújuló energiaforrásokat alkalmazó közlekedési módokkal szemben. A mikromobilitás a városi közlekedési módok innovatív formája, amely lehetőséget biztosít az első és utolsó kilométeres utazásokra (first- and last-mile mobility), és jellemző rá a fenntarthatóság és a költséghatékonyság. A big data mint eszköz megadhatja a lehetőséget a piaci szolgáltatók és a szakpolitikai döntéshozók számára, hogy a jövő fenntartható(bb) városait hozzák létre (Abduljabbar et al., 2021; Bibri, 2021; Wang et al., 2021).

Tanulmányunk fókuszát alapján egy másik lényeges motívum a korábbi szakirodalmi áttekintő tanulmányok körében a big data elemzési módszerek technikai oldalról történő megközelítése. Sajátos

csoportot képeznek ebben a módszertani kutatások. A módszertani vizsgálatok első csoportjába tartoznak azok, amelyek a szakpolitika számára készülnek, például egy a város számára jelentős témában, mint a mikromobilitás (Abduljabbar et al., 2021). A szakpolitika mellett érdemes megemlíteni a közpolitikai jellegű kutatásokat is, amelyek célja általában különböző, a lakosságot érintő tématerületek feltárása, mint például a környezeti igazságosság vizsgálata a pekingi levegőszennyezés példáján (Xu et al., 2019). A politikai jellegű kutatások mellett érdemes megemlíteni a kizárólag módszertani jellegű kutatásokat és azokat is, ahol kísérleti és fejlesztési cél áll a tanulmányok középpontjában. Egyes szerzők például a big data-adatok feldolgozási, elemzési folyamatait tekintették át, kitérve azok előnyeire és hátrányaira (ezekről részletesebben lásd pl. Liu et al., 2016; Pai et al., 2018).

A városi mobilitást big data-technológiával és -megközelítéssel vizsgáló korábbi nemzetközi tanulmányok jellemzőinek áttekintése a magyarországi városkutatás számára is számos tanulsággal szolgálhat. Magyarországon ugyanis eddig viszonylag kevés olyan kutatás zajlott, amelynek keretében a városi mobilitás alaposabb megismerésére big data elemzési módszereket alkalmaztak. Az ebbe a körbe tartozó hazai kutatók munkájáról elmondható, hogy a különböző adatforrások közül alapvetően a mobilcellaadatokat részesítik előnyben. Ezekben a tanulmányokban többnyire magyarországi településeken – Budapest, Győr, Szeged, Szentendre – mérték a népesség napi fizikai térbeli aktivitását. Közös bennük az is, hogy jellemzően egy-egy turisztikai esemény idejében készültek a vizsgálatok, vagy pedig a turizmus tekintetében kiemelkedő települést vizsgáltak (Felde et al., 2014; Kondor et al., 2020; Pintér et al., 2018). Van olyan kutatás, ahol közösségimédia-adatokat vetettek össze mobilcellaadatokkal azzal a céllal, hogy feltárják a turisták látogatásának intenzitását, hogy külföldről vagy belföldről érkeznek a városban zajló eseményre, valamint hogy megvizsgálják, hogyan mozognak a városban, milyen helyeket látogatnak meg (Kovács et al., 2021). Összességében a magyarországi kutatásokról megállapítható, hogy a big data elemzési módszerek közül a mobilcellaadatokat alkalmazzák leggyakrabban, szemben a nemzetközi szakirodalommal, ahol e módszerek szélesebb tárháza jelenik meg.

Míg globálisan nem ritka az olyan átfogó vizsgálat, amely rendszerben elemezné a korábban megjelent, városi mobilitással foglalkozó tanulmányokat (pl. Kong et al., 2020; Li et al., 2017; Torre-Bastida et al., 2018; Wang et al., 2020), Magyarországon big data-kutatásból általában véve is viszonylag kevés van, szakirodalmi áttekintést pedig egyáltalán nem találtunk (bár a big data kapcsán születtek már általános jellegű, áttekintő tanulmányok, pl. Ságvári, 2017; 2019). Ezért is fontos tehát feltérképezni, mi jellemző a big data által meghatározott, városi mobilitást középpontba helyező kutatási területre. Tanulmányunk fő célja annak a feltárása, hogy a big data-szemponthú kutatási megközelítés és az ahhoz kapcsolódó módszerek miként jelennek meg a városi mobilitásra irányuló kutatásokban. További célunk, hogy a magyar tudományos közösséget tájékoztassuk a big datát alkalmazó városi mobilitáskutatás trendjeiről, legfontosabb jellemzőiről, és inspiráljuk a hazai kutatókat, illetve hozzájáruljunk a témával kapcsolatos diskurzushoz. Ennek keretében különösen az alábbi kérdésekre keressük a választ:

1. Milyen mobilitási módok vizsgálatánál használták eddig a big data-jellegű adatokat és -módszereket a városi mobilitás kutatásában?
2. A városi mobilitással kapcsolatos big data-tanulmányok megjelenése milyen térbeli mintázatot és időbeli dinamikát mutat (mely országokban és mikor jelentek meg)?
3. A big datát alkalmazó tanulmányokban mekkora időintervallum és földrajzi lépték képezi a vizsgálat alapját?
4. Milyen adatforrásokat, adattípusokat és elemzési módszereket alkalmaznak az egyes tanulmányok szerzői?
5. Milyen szakpolitikai kapcsolódás mutatható ki az ide tartozó tanulmányokban?

Tanulmányunk következő fejezeteiben először a kutatás során alkalmazott adatgyűjtési és -elemzési módszereket mutatjuk be, majd az általunk végzett szakirodalmi áttekintés eredményeit ismertetjük, végül pedig a tanulmányt az eredményekből levont következtetésekkel zárjuk.

## MÓDSZEREK

A korábban publikált releváns szakirodalom megismerése a legtöbb kutatás alapfeltétele az elméleti keretek meghatározásakor. A szakirodalmi áttekintés (literature review) esetében azonban szükséges a kapcsolódó kutatási módszertan szabályainak betartása. A szakirodalmi áttekintésnek több típusa van (Snyder, 2019), és az adott kutatás céljától függ, hogy ezek közül melyiket alkalmazzuk: használható például kutatási tervek összeállítására, korábban kisebb mértékben vagy egyáltalán nem vizsgált témák feltárására vagy különböző kutatási kérdések tárgyalására. Tanulmányunk elkészítéséhez a különböző típusok közül a „szisztematikus szakirodalmi áttekintést” alkalmaztuk. A szisztematikus szakirodalmi áttekintés először az orvostudományban jelent meg, viszont egyre inkább kezd elterjedni a társadalomtudományok területén is (Tikito & Souissi, 2019). Ennek az elemzési módszernek a célja az adott téma szempontjából releváns – előzetesen megállapított feltételeknek megfelelő – szakirodalmi források teljes körű felkutatása. A keresési feltételek és szabályok betartásával minimálisra csökkenthető az esetleges torzítás, így a kapott eredmények biztosítják a megalapozott következtetéseket. A szisztematikus szakirodalmi áttekintés azért is hasznos, mert több potenciális hozadéka is van. Alkalmazásával feltárható, ha több – akár egymástól független – tanulmány tendenciózusan hasonló eredményre jutott egy vizsgált jelenséggel kapcsolatban, illetve felfedezhetők az addig publikált szakirodalomban különböző hiányosságok, amelyek a jövőbeli kutatási irányokat is meghatározhatják (Snyder, 2019).

A szisztematikus szakirodalmi áttekintés módszertana előre meghatározott és dokumentált szabályok szerint alakul. A kutatási célok és kérdések meghatározásán túl a módszertan magában foglalja a megfelelő keresőszavak kiválasztását és az arra vonatkozó befogadási és szűkítési kritériumokat is, így elvégezhetjük a keresést a tudományos adatbázisban. A bibliometriai adatok kvantitatív és kvalitatív elemzési módszerek alkalmazásával elemezhetők, majd a kapott eredmények értékelése következik. A szakirodalmi áttekintések fontos szerepet töltenek be a tudományos kutatások területén,

mivel a kapott eredmények iránymutatásként szolgálnak a szakpolitikák számára és új kutatások alapjául is szolgálhatnak (Abduljabbar et al., 2021; Snyder, 2019).

A tanulmányunkhoz használt szakirodalmi áttekintés célja bemutatni a big data-módszerek lehetőségeit a városi mobilitás vizsgálatában azáltal, hogy áttekintjük a tanulmány szempontjából releváns szakirodalmi forrásokat. Az elemzésbe vont tanulmányok kiválasztási kritériumai a következők voltak. A szakirodalmi forrásokat a Scopus tudományos bibliográfiai adatbázisból gyűjtöttük össze. Az adatbázis kiválasztását az indokolta, hogy a Scopus a lektorált szakirodalom legnagyobb multidiszciplináris nemzetközi adatbázisa, amelynek keresőfelülete és intelligens eszközei lehetővé teszik a releváns szakirodalmi források gyors és egyszerű felkutatását.

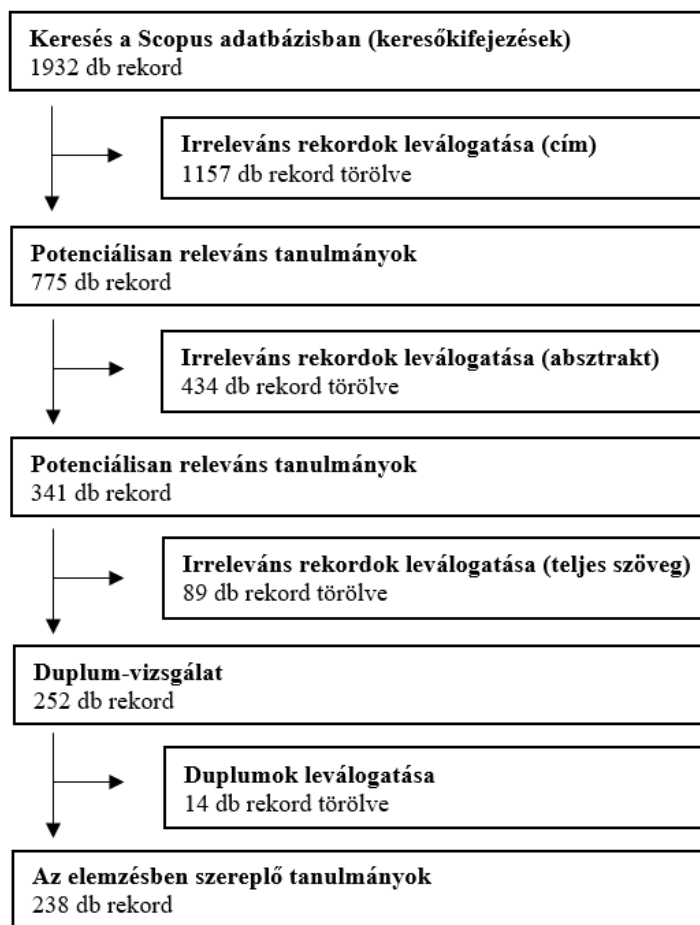
A Scopus adatbázisban történő kereséshez szűkítési kritériumokat határoztunk meg. Típus szerint a mintába kizárólag lektorált tudományos folyóiratcikket válogattunk be, amelyekben címre, absztraktra és keresőszavakra szűkítettük a találatokat. Nyelvi korlátként az angol nyelvet választottuk. A tanulmányokkal szemben szakterületi szűkítést nem alkalmaztunk, illetve idő- vagy térbeli szűkítési kritériumot (pl. publikálás ideje és helye) sem adtunk meg.

A nyelvi szűkítés miatt kizárólag angol nyelvű keresőkifejezéseket alkalmaztunk. Az adatgyűjtéshez a keresési kifejezéseket a korábban ismertett tanulmányok alapján határoztuk meg, amelyek a big data és a városi mobilitás jellemzőit fedik le. Ezek első tagja minden esetben a „big data” volt, amely a korábban olvasott tanulmányok címeiben és kulcsszavai között gyakran szerepel. A második tag minden esetben egy-egy, a városi mobilitási kutatásokban gyakran előforduló kifejezés volt, vagyis rendre az alábbiak egyike: urban mobility, human mobility, micromobility, mobility patterns, smart city, urban transport, urban activity, activity patterns, trajectory.

A Scopus adatbázisból lekérdezett cikkeknel különböző kizárási kritériumokat alkalmaztunk. A folyamat több lépést foglalt magában, amely során megkaptuk az elemzésre alkalmas cikkek listáját. A szakirodalmi feldolgozáshoz használt minta kialakítása során a Scopus adatbázis keresőfelületére beírtuk az egyes keresőkifejezéseket, és minden találatot megvizsgáltunk, majd először cím alapján zártuk ki a nem releváns forrásokat. A fennmaradó források absztraktjainak tanulmányozása után szintén kizártuk a nem releváns találatokat, illetve a duplumokat. Végül a megmaradt források teljes szövegének elolvasása alapján zártuk ki a témánk szempontjából irreleváns cikkeket, **így kaptuk meg** az elemzésben szereplő tanulmányok végső listáját (1. ábra).

Az elkészült adatbázis 238 darab cikket tartalmaz, amelyekről kigyűjtöttük az elemzéshez szükséges szempontokat. Az elemzés során kvantitatív és kvalitatív módszereket alkalmaztunk. Kvantitatív módszerekkel vizsgáltuk az adatbázis cikkeit megjelenési év és a bennfoglaló folyóiratok szerint, valamint a mintaterületek jellemzői alapján. A kvantitatív elemzés ezen túl alapvetően leíró statisztikát, viszonyszámokat és a grafikusán ábrázolt diagramok elemzését foglalja magában. A kvalitatív elemzés során témákat igyekeztünk azonosítani a további elemzéshez. A tanulmányok szövegét a következő szempontok alapján vizsgáltuk: milyen vizsgálati módszer, adattípus és szakpolitikai vonatkozások alakítják a big data alkalmazását a városi mobilitás vizsgálatában.

1. ábra: A szakirodalmi áttekintés során alkalmazott kizárási kritériumok  
 Figure 1. Exclusion criteria used in the literature review



Forrás: saját szerkesztés  
 Source: edited by authors

## EREDMÉNYEK

A big data használata 2010 óta igen gyorsan bővül, melyet az ebben az időszakban keletkezett, kapcsolódó tanulmányok számának növekedése reprezentál. E növekedéshez legnagyobb mértékben Kína és az Amerikai Egyesült Államok járultak hozzá, amit jól mutat, hogy ezekben az országokban a leginkább előrehaladott a nagy adattömeg hasznosítását célzó digitalizáció is (Raban & Gordon, 2020). Azonban a fenti folyamat a világ más részein, például az európai országokban is egyre nagyobb jelentőséggel bír.


A tanulmányunkban elemzett publikációk megjelenési év szerinti megoszlásáról elmondható, hogy számuk 2012 óta dinamikusan növekszik, alátámasztva a big data egyre nagyobb jelentőségét (2. ábra). A bővülés ütemének bemutatásához láncviszonyszámokat számoltunk, amelyek alátámasztják a cikkek számának évenkénti dinamikus növekedését, azonban kiugróan nagy gyarapodást 2014



és 2015 között, 2016 és 2017 között, 2017 és 2018 között, illetve 2020 és 2021 közötti időszakban figyeltünk meg (1. táblázat).

2. ábra: A vizsgált tanulmányok száma a megjelenés éve szerint

Figure 2. The number (bar charts) and cumulative number (line chart) of papers included in the sample by year of publication



Forrás: saját szerkesztés  
 Source: edited by authors

1. táblázat: A vizsgált tanulmányok számának változása évenként

Table 1. The number of studies included in the sample by year of publication (top row) and changes in the number of studies included in the sample (1.00=data of the previous year; bottom row)

Évek	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
Megjelent cikkek évenként (darab)	1	2	5	16	28	50	85	123	171	238
Megjelent cikkek változása évenként (%)	-	2,00	2,50	3,20	1,75	1,79	1,70	1,45	1,39	1,39

Forrás: saját szerkesztés  
 Source: edited by authors

A tudományos teljesítmény mérésének egyik lehetősége a tudományos kiadványok értékelése, amelyek esetében az egyéni munkák helyett az azokat fogadó folyóiratokat rangsorolják. Erre alkalmas a

Scimago tudományometriai adatbázis SJR<sup>5</sup> mérőszáma. Az SJR-érték a folyóiratok minőségét mutatja, amely a kvartilis besorolással összefüggésben megfelelő értékelési lehetőséget ad. Ezek Q1-Q4 besorolásúak lehetnek, ahol a Q1 a legmagasabb értékű. Továbbá használják még a decilisen alapuló besorolást is, kiemelten a D1 kategóriát, illetve a centilisen alapulót, ahol ez releváns, kiemelten a C1 kategóriát (Kovalcsik et al., 2021).

Az elemzésünkben szereplő folyóiratokat a mintán belüli előfordulásuk gyakorisága szerint ábrázoltuk (3. ábra). Az egyik tényező, amely a folyóiratok szerinti megoszlást befolyásolta, a nyílt hozzáférésű (ún. open access) folyóiratok elterjedése. Az open access (OA) publikálási forma az 1990-es évekre vezethető vissza. Megjelenése azáltal könnyítette meg a kutatók helyzetét, hogy a tudományos eredményeket széles körben elérhetővé tette. Az OA-tanulmányok közléséért ugyan a kiadók gyakran megjelentetési díjat (Article Processing Charge, röviden APC) számolnak fel, de az ilyen publikálási forma előnye, hogy lehetővé teszi a szakértői értékeléssel ellátott tudományos művek pénzügyi, technikai és jogi korlátozásoktól mentes, szabad – általában online – elérhetőségét és újrafelhasználását (Laakso et al., 2011). A mintánkban szereplő tanulmányok bennfoglaló folyóiratainak térbeli vetületére jellemző, hogy a kiadók többnyire Nyugat-Európában (MDPI; ELSEVIER) vagy Észak-Amerikában (IEEE) találhatóak. Azt azonban érdemes figyelembe venni, hogy a Scopusban történő keresés során a szűkítési feltételek miatt csak az angol nyelvű folyóiratokra kerestünk rá. Az általunk vizsgált folyóiratok között megtalálhatók OA-folyóiratok is, mint az ISPRS International Journal of Geo-Information vagy a Sustainability. Az olyan kiadók, mint az Elsevier folyóiratai nem nyílt hozzáférésűek, de globális szereplők a kiadói piacon, amelyek nagyon sok folyóiratot vásároltak fel az idők folyamán, így nem meglepő, hogy ilyen kiadók által kezelt kiadványok szerepelnek a lista élmezőnyében. A tanulmányunkban szereplő Scopus adatbázist is az Elsevier hozta létre 2004-ben (De Moya-Anegón et al., 2007).


A vizsgálatunkban kiemelt folyóiratok fő profilja a városi tér vizsgálata. Mivel kezdettől fogva a városi mobilitással kapcsolatos kutatásokat kerestünk, ez determinálta, hogy a végső mintában sok lesz a „városi témájú” folyóirat. Azonban ezt az általános témát az egyes szerzők egymástól különböző nézőpontokból közelítik meg, amelyeket három nagyobb csoportba sorolhatunk. A legjellemzőbb az informatikai megközelítés, ahol a városi tér időbeli változásait vizsgálják geoinformatikai módszerekkel, a gépi tanulás és a mesterséges intelligencia segítségével pedig modellezik a városi rendszereket, nagy hangsúlyt fektetve a közlekedés kutatására (Blais et al., 2020; Kan et al., 2019; Wang et al., 2021; Zhu et al., 2021). Azoknál a folyóiratoknál, ahol nem az informatikai megoldásokon alapulnak a kutatások, fontos kutatási terület a fenntarthatóság, beleértve a kulturális, környezeti, gazdasági és társadalmi fenntarthatóság aspektusait is (Zhao et al., 2019). A harmadik fő profilként említhető a városi közlekedési rendszereknek és a városi mobilitásnak a kutatása, összhangban a várostervezéssel. A Cities folyóirat ilyen szempontból azért számít egyedinek, mert párbeszédet biztosít a kutatók és a döntéshozók között, elősegítve az eredmények gyakorlati megvalósítását (Li et al., 2020; Tu et al., 2018). A vizsgált folyóiratok elemzéséből megfigyelhető a kiadói tevékenység globális

<sup>5</sup> Scimago Journal Rank

centrum–periféria mintázata, mivel a kiemelt folyóiratok mind centrum térségekhez köthetők, ez a tendencia pedig a mintaterületek megoszlásánál is megfigyelhető.

3. ábra: A vizsgált tanulmányok száma folyóiratok szerint, kiemelve a mintában leggyakrabban előforduló folyóiratokat

Figure 3. The number of analysed papers by journal, highlighting the most frequent journals in the sample



Forrás: saját szerkesztés  
 Source: edited by authors

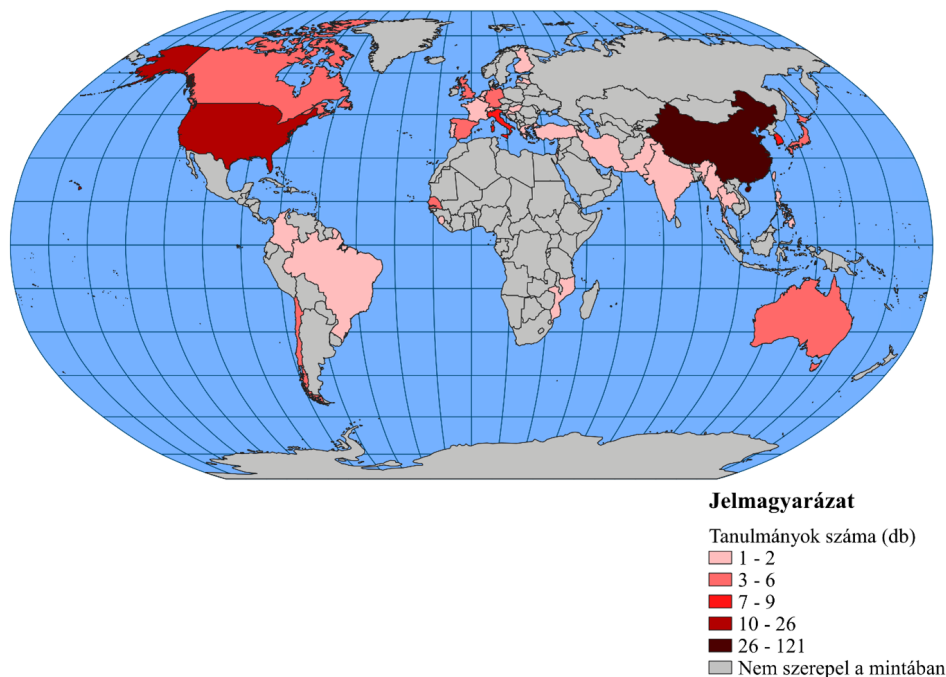
A big data jelentőségét mutatja az a megállapítás, miszerint a következő gazdasági világrendet az adataalapú tevékenységek határozzák meg. Különböző forgatókönyveket figyelembe véve valószínű, hogy a jövő legnagyobb adat-előállítója az Amerikai Egyesült Államok és Kína lesz majd, ugyanakkor érdemes megemlíteni még a nyugat-európai országokat is (Chakravorti et al., 2019).

A mintában szereplő tanulmányok országonkénti és nagyrégiókénti megoszlásáról elmondható, hogy a big datát használó kutatások Kelet- és Délkelet-Ázsiában, Észak-Amerikában és Európában vannak legnagyobb arányban jelen. A kapott eredményeket támasztja alá az IMD (International Institute for Management Development [IMD], 2021) digitális versenyképességi rangsora is. Azok az országok, ahol a big data alkalmazása gyakori, ebben az országgrangsorban is előrébb található. Az első az Amerikai Egyesült Államok, ugyanakkor Kelet- és Délkelet-Ázsia, valamint Európa országai is előkelő helyen szerepelnek. A rangsor végén szereplő országok listája hasonlóságot mutat a mintába került tanulmányok országonkénti megoszlásával: többnyire olyan országok találhatóak itt, amelyek kevésbé járnak elől a big data alkalmazásában. Az egyedüli kivétel Ausztrália, amelyhez viszonylag kevés big datát alkalmazó tanulmány kapcsolódik, ugyanakkor a digitalizációs rangsor első harmadában foglal helyet (IMD, 2021).

Az eredmények tehát arra utalnak, hogy összefüggés van egy térség digitalizációjának mértéke és aközött, hogy mennyi Scopusban jegyzett nemzetközi publikáció jelenik meg az adott térséghez

kapcsolódóan (4. ábra, 5. ábra). A mintában szereplő tanulmányok alapján a digitalizációt tekintve fejlettebb régiókban végzett kutatások gyakran különböző közlekedési módokhoz köthető mobilitással, a városi térszerkezettel és területhasználattal, valamint a turizmussal foglalkoznak (Ge et al., 2019; Liao, 2021; Yang et al., 2020). Ezzel szemben a digitalizációban kevésbé fejlett régiókban végzett kutatások többnyire azt vizsgálják, hogy milyen tömegközlekedési eszközökkel és miként mozog az ember a városi térben (Daniel et al., 2020; Tarcisio et al., 2018). A fenti két fő típus mellett egyes tanulmányok tematikája a társadalmi csoportok mobilitására, illetve az elmúlt években a Covid19-járványhelyzet miatt a közegészségügyet érintő mobilitásra is irányult (Chapple et al., 2022; Jiang et al., 2021).

4. ábra: Az elemzett tanulmányokban szereplő esettanulmányok száma országonként  
 Figure 4. Number of case studies in the analysed papers by country




Forrás: saját szerkesztés  
 Source: edited by authors

A vizsgálati minta alapján a big data-módszerek elterjedéséről megállapítható, hogy egyes országokban, mint Kína, az Amerikai Egyesült Államok és Dél-Korea szinte folyamatos növekedés tapasztalható, míg máshol, mint Olaszország, Spanyolország, Ausztrália és Szingapúr a nagyobb időbeli fluktuáció a jellemző. Az egyéb kategória trendjéről elmondható, hogy visszatükrözi a big data egyre növekvő jelentőségét, mivel a magterületek mellett máshol is növekszik azoknak az országoknak a száma, ahol alkalmaznak big data-kutatásokat (6. ábra).

Az általunk vizsgált tanulmányok szerzői rövid adatgyűjtési periódusú és hosszabb periódusú kutatásokat egyaránt végeztek. A rövid adatgyűjtési periódusra jellemző, hogy az adatok felvételének időtartama egy naptól egy hónapig terjed, és valamennyi adattípust alkalmazzák. Gyakori tématerület a városon belüli mobilitás és utazási szokások vizsgálata, a forgalomelemzés és a különböző

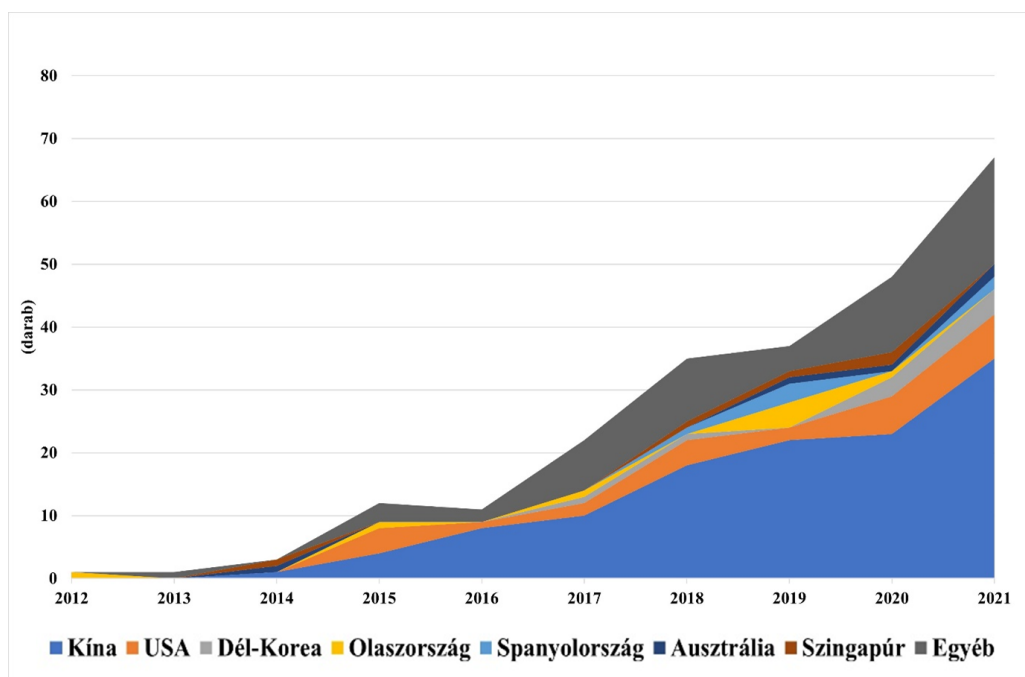
eseményekhez – általában fesztiválokhoz – kapcsolható turisztikai kutatások (Peng et al., 2021; Wang et al., 2020; Xu et al., 2021).

5. ábra: A mintában szereplő tanulmányokban lévő mintaterületek nagyrégióinként  
 Figure 5. Case-study areas in the analysed papers by macroregion



Forrás: saját szerkesztés  
 Source: edited by authors

6. ábra: Az elemzett tanulmányok országonként és évenként  
 Figure 6. The number of analysed papers by country by year



Forrás: saját szerkesztés  
 Source: edited by authors

A hosszabb adatgyűjtési időszakra jellemző, hogy néhány hónaptól néhány évig is tarthat. Az ebbe a kategóriába tartozó publikációk jellemző tématerülete a lakosság városon belüli mobilitása és a

turizmus vizsgálata. Szemben a rövidtávú adatgyűjtéssel, a tanulmányok e csoportjában szintén megfigyelhető, hogy turizmus szempontjából jelentős területeket vizsgálnak közösségimédia-adatok elemzésével, így fogalmazva meg javaslatokat a mintaterületek turizmustervezésére vonatkozóan (Chen et al., 2021; Giglio et al., 2020).

Az elemzésre kiválasztott tanulmányokban előforduló különböző adattípusokat három nagy csoportra osztottuk (2. táblázat). E csoportok egyike a felhasználói adatok csoportja, amelyeket közvetlenül a felhasználó tölt fel és tesz elemezhetővé. Ide sorolhatók a közösségimédia-bejegyzések vagy a képmegosztó oldalakra feltöltött online fényképek. Az adatforrások másik csoportját alkotják az eszközadatok, amelyeket különböző eszközök segítségével, mint GPS vagy mobilcella gyűjtenek. Az adatforrások harmadik csoportjába tartoznak a forgalmi vagy tranzakciós adatok, amelyek alapját a különböző kártyás tranzakciók vagy weboldalon történő keresések képezik (Li et al., 2018).

2. táblázat: Big data adattípusok a városi mobilitás kutatásában  
Table 2. Types of big data in urban mobility research

<b>Big data adattípusok a városi mobilitás kutatásában</b>		
<b>Felhasználói</b>	<b>Eszköz</b>	<b>Forgalmi/tranzakciós</b>
Közösségimédia	GPS	Okoskártya
Felhasználók által feltöltött tartalmak	Mobilcellaadatok	Kártyás vásárlások
	Forgalomszámláló berendezés	Internetes keresések
	Bluetooth	Weboldal letöltések

Forrás: saját szerkesztés Li et al. (2018) alapján  
Source: edited by authors based on Li et al. (2018)

A közösségi média fellendülése új platformot biztosít a felhasználók által generált adatok megosztására. A közösségimédia-adatok leginkább a turizmust érintő kutatásokban jelennek meg, mivel lehetőséget kínálnak a turisták számára, hogy írásban vagy geotaggel ellátott képek formájában szélesebb rétegekkel is megosszák az utazásukkal kapcsolatos tapasztalataikat (Lin et al., 2021). A közzétételre alkalmas felületek az online blogok, mint például a Twitter, a kínai Sina Weibo vagy a Foursquare. Az ilyen adatokat megosztó felhasználók tapasztalatai értékesek lehetnek más potenciális turisták számára, illetve a kutatók és a politikai döntéshozók számára is (Li et al., 2018). A közösségimédia-adatokkal kapcsolatban igen lényeges, hogy mára több milliárd ember tekinthető ezek felhasználóinak, akik tevékenységeikről egyre több adatot generálnak. Ezeknek az adatoknak az értékét az adja, hogy geotaggel ellátott adatokról van szó, melyeknek földrajzi információs tartalma van (pl. koordináták vagy helynevek). Nagy mennyiségű, API<sup>6</sup> segítségével ingyen beszerezhető adatforrásról van szó, amely tér-időbeli információkat hordoz és lehetővé teszi az információgyűjtést eseményekről, helyekről és a társadalmi és viselkedési jellemzőkről (Yang et al., 2018).

A technológia fejlődésével különböző eszközök, szenzorok tették lehetővé az emberek mozgásának hatékonyabb követését a városi térben. Ilyen eszközök által gyűjtött adatok például a GPS, a mobil-

<sup>6</sup> API: application programming interface, alkalmazásprogramozási felület.

cella, a Wifi és Bluetooth, valamint a forgalomszámlálásra alkalmas szenzorok adatai. Ezeket gyakran használják a városi mobilitás kutatására, beleértve a területhasználatot és az emberek közlekedési jellemzőit is (Li et al., 2021; Zhao et al., 2020). Az említett adatokat a turizmuskutatók is alkalmazzák, mivel lehetőséget biztosítanak egy-egy turisztikai esemény (pl. fesztivál) városi térre gyakorolt hatásának a vizsgálatára (Park et al., 2020). Forgalomelemzésre leginkább a forgalomszámláló, forgalomértékelő szenzorok adatait veszik igénybe a kutatók (Liao, 2021), így ez az a terület, amely leginkább támaszkodik az eszköz által gyűjtött adatokra (Li et al., 2018). Az eszköz által gyűjtött adatok széles körben elterjedtek, azonban ez az elérhetőség nem teljes. Ennek oka, hogy vannak olyan régiók, melyek kevésbé digitalizáltak, és az ehhez kapcsolódó eszközök sem terjedtek el széles körben, illetve vannak olyanok, akik tudatosan próbálják magukat kizárni a digitalizációból. Az ilyen adatok alkalmasak az egyéni útvonalak, utazások becslésére, ezáltal lehetőséget biztosítanak a városi mobilitás vizsgálatára, közlekedési útvonalak azonosítására (Mamei et al., 2019).

A forgalmi/tranzakciós adatok elsősorban a tömegközlekedéssel és a turizmussal kapcsolatos kutatásoknál bizonyulnak hasznosnak. Segítségükkel nyomon követhetjük az online vásárlásokat, foglalásokat, jegyvásárlásokat és weboldal-látogatásokat is. Ezek az adatok tartalmazzák a helyszínt, ahol használták az adott kártyát és az időpontot, amikor használták azt. Tömegközlekedés esetében gyakran alkalmazzák az okoskártyaadatokat (Zhou & Murphy, 2019), melyek rögzítik a járműre történő fel- és az onnan való leszállások időpontját, így alkalmazásukkal a kiindulási- és célállomások területi mintázatait is lehet vizsgálni (Kim et al., 2018; Li et al., 2018).

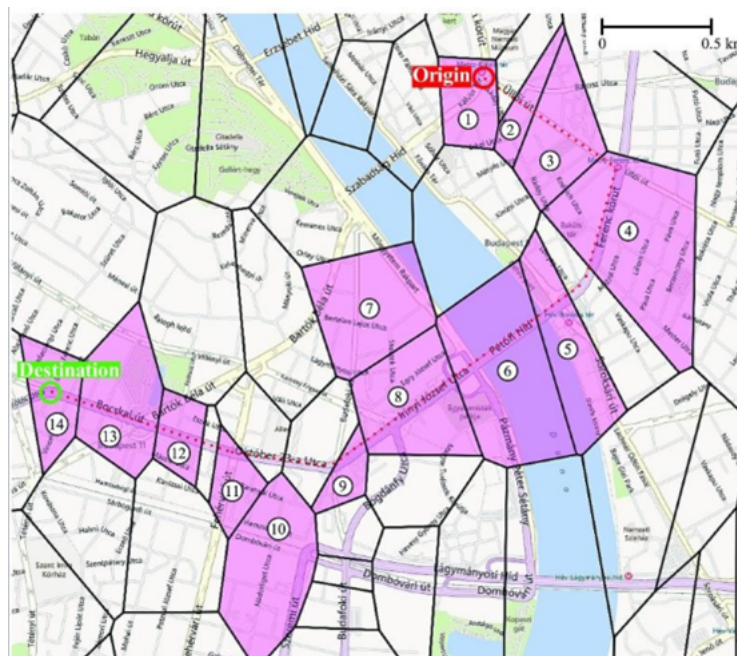
Az általunk elemzett tanulmányokban alkalmazott adattípusokhoz köthető módszereket két nagy csoportba soroltuk. Az egyik csoportba azok a közlemények tartoznak, amelyek elkészítéséhez hagyományos statisztikai módszereket alkalmaztak a kutatók, a másikba pedig azok, amelyekben gépi tanulást, mesterséges intelligenciát vettek igénybe. A gépi tanulást alkalmazó módszerek jellegzetessége, hogy nincsenek előzetes felvetéseik a modellezendő jelenségekkel kapcsolatban, ami jellemző a függő és független változók kapcsolatára is. Ehelyett a rendelkezésre álló adatok alapján próbálnak eredményt találni (Gyarmati, 2019; Nyitrai, 2021). Összeségében megállapítható, hogy a hagyományos statisztika az adatpontok közti kapcsolatokat tárja fel, a következtetésekre koncentrál. Ezzel szemben a gépi tanulás az előrejelzésre fókuszál tanulási algoritmusok segítségével (Bzdok et al., 2018).

Az egyik jellemző elemzési módszer az OD-mátrix (kiindulási-rendeltetési mátrix), amely jellemzően az egyéni mobilitás vizsgálatára alkalmas és mobilcellaadatok használatán alapul. Az OD-mátrix lényege, hogy az egyéni utazási adatokat olyan formában generálják, amelyben minden kiindulási ponthoz tartozik egy rekord (sor), és minden célállomáshoz tartozik egy mező (oszlop). Ez a módszer az útvonalak számát veszi figyelembe a kiindulási ponttól a célállomásig. Az OD-mátrix használata feltételezi, hogy a vizsgálati területet véges sokaságra, övezetekre osztják fel, és rögzítik az egyik övezetből a másik övezetbe történő utazások számát egy adott napon, adott időpontban. Ezeket az övezeteket általában Voronoi-cellák reprezentálják (7. ábra). A Voronoi-tesszelláció során minden cellát egy-egy adóvevő toronyhoz rendelnek úgy, hogy az adott Voronoi-cella minden pontja

közelebb van a hozzá tartozó toronyhoz, mint bármely más toronyhoz. Ha az adóvevő antennák koordinátái rendelkezésre állnak, akkor a cellák által lefedett földrajzi terület mérete megbecsülhető, az egyes bázisállomások hatásterülete pedig könnyen behatárolható a kommunikáció fizikai aspektusainak (pl. rádióhullámok terjedése, interferencia stb.) ismerete nélkül. Így a Voronoi-tesszelláció hatékony módszert nyújthat egy hívás térbeli mozgásának nyomon követésére, például a mobil jelzési események megfigyelésével. A fenti módszer lényege tehát az, hogy kisebb térbeli felbontású, illetve bizonytalan lokációval rendelkező adat esetén (pl. mobilcella) megfelelő hibahatár mellett meg lehet becsülni a felhasználó helyét (Candia et al., 2008; Tettamanti & Varga, 2014).

Két fő megközelítést különböztetünk meg az OD-mátrixok használatában: az időalapú mátrixot, ahol az elemzés a mobilitás közvetlen becslésére összpontosít a mobilcellaadatok sorozatából, illetve a rutinalapút, ahol az elemzés a rutinszerű mozgásmintákon alapszik, mint a munkába vagy iskolába járás. Az időalapú mátrix esetében a kutatók egy adott nap adott időszakára összpontosítanak. Megbecsülik a felhasználók mozgását a kiválasztott időszakban generált mobilcellaadatok alapján, így a valós időben számítható a vizsgált időpontban ténylegesen zajló utazások száma. A rutinalapú mátrix az ún. rutinszerű mozgásokra összpontosít. Rutinszerű mozgások alatt azokat az utazásokat értjük, amelyet napi szinten rendszeresen megteszünk, mint az iskolába vagy munkába utazás. Az ilyen jellegű mozgásokat útgeneráló modellekből számítják ki, az adott időpontban a mintaterületen tartózkodó személyekre vonatkoztatva (Chua et al., 2020; Mamei et al., 2019; Wu et al., 2019; Xie et al., 2021).

7. ábra: Voronoi-cellák mintaterület felosztásához OD-mátrix alkalmazása esetén  
 Figure 7. Voronoi polygons for the partitioning of case-study area in case of using OD Matrix



Forrás: Tettamanti & Varga (2014)  
 Source: Tettamanti & Varga (2014)

A klaszterezés szintén jellemző módszer big data alkalmazásakor a városi mobilitás kutatásában. A kutatók az ilyen vizsgálatok keretében kiválasztják az egyes utazások azonos jellemzőit, és figyelembe



veszik az adott utazás kezdési és befejezési időpontját, illetve a kiindulási- és célállomás földrajzi helyét (koordinátáit). Végül soron a klaszterezéssel rendszerint a hasonló jellemzőkkel rendelkező utazásokat vagy a mobilitással kapcsolatban előforduló tevékenységeket csoportosítják, mint például az egyéni vagy a tömegközlekedéssel történő utazások. Az utazások közti távolságot a felvett vektorok közti távolságok adják meg. A városi mobilitáskutatás területén két klaszterezési algoritmus jellemző, a k-közép és a DBSCAN (Jalali et al., 2017).

A k-közép egy iteratív klaszterező algoritmus, amelynek keretében „n” számú megfigyelőt osztanak fel klaszterek között, az „n” értéket pedig az algoritmus elindítása előtt választják ki. A módszer használata során „k” számú kezdeti klaszterközpontot választanak ki, és kiszámítják az egyes klaszterek központjának a távolságát az összes utazástól, majd a klaszterközpontokat hozzárendelik a klaszterekhez. Minden utazást a legközelebbi központtal rendelkező csoportba sorolnak be. A k-közép alkalmazásakor kiszámítják az átlagos távolságot az egyes utazások és a klaszterközpontok között, hogy megtalálják az új központot. Végül addig ismétlik a fenti lépéseket, ameddig a klasztertagok nem változnak. A k-közép klaszterezést olyan városi mobilitással kapcsolatos tanulmányokban használják, amelyekben az utazásokat szándékozzák optimalizálni, például a városban megtett utak racionalizálásához kiszámítják, hogyan lehet a legtöbb utaskilométert megtakarítani, ami jelentős eredményekkel járhat az utazási idő és a fenntarthatóság szempontjából is (Hoseinzadeh et al., 2020; Jalali et al., 2017). A k-közép klaszterezést használják még a turizmusban is a helyiek és a desztinációba érkező turisták térpályáinak az azonosításához (Sun et al., 2021).

A DBSCAN egy sűrűség alapú térbeli klaszterezési algoritmus. A módszerrel lehetséges a sűrűséggel összekapcsolt pontok halmazából a kellő sűrűséggel rendelkező területeket klaszterekre felosztani és tetszőleges méretű klasztereket meghatározni a zavaros térbeli adathalmazokban. A DBSCAN fejlett jellemzőkkel rendelkezik, amelyek alkalmassá teszik a különböző alakú minták észlelésére, valamint a természetes klaszterek kialakítására és azok adattéren belüli elrendezésére. Ennél az algoritmusnál két paraméter megadása szükséges: az  $\epsilon$ , amely a klaszter szomszédsági sugara, illetve a  $\mu$  pozitív egész szám, amelyet sűrűségi korlátnak nevezünk. A DBSCAN klaszterezést olyan városi mobilitással kapcsolatos kutatásokban használják, mint például a turisztikai hot spot területek vizsgálata, taxik útvonalainak elemzése „nagysebességű” pontok és megállási pontok alkalmazásával vagy aktivitási területek lehatárolása, amely utóbbiból a népesség mobilitási jellemzőire lehet következtetni (Rodríguez-Echeverría et al., 2020).

A fenti módszerek kapcsán azonban érdemes figyelembe venni, hogy az eredeti adatok felbontása a vizsgálat során is változhat. Például egy mobilcellaadatokat szolgáltató vállalat a felhasználók azonosíthatatlanságának biztosítása érdekében az adatokat nagyobb poligonokba rendezheti, így a térbeli felbontás nem feltétlenül olyan pontos, mint a signaling (GPS) adatok. Területi összevonásnál az is előfordulhat, hogy a kisebb mozgások az adattanszformáció révén elvesznek az adatsorból. Hasonló jelenség merülhet fel az időbeli felbontással, ugyanis ha az adatok bizonyos idő után újrakódoláson esnek át, az azt jelenti, hogy egy-egy felhasználó csak addig követhető normál módszerekkel. Össz-

ességében tehát a big data-val való munka az adatminőség és a feldolgozási módszer függvényében adatvesztéssel is járhat (lásd pl. Kondor et al., 2020, p. 21).

A gépi tanulási technikák fejlődése számos hatékony osztályozási modellt eredményezett, így egyre gyakrabban alkalmazzák ezeket a kutatók arra, hogy következtetéseket vonjanak le bizonyos városi tevékenységtípusokra. E tekintetben a gépi tanulási technikák csoportján belül felügyelt és felügyelet nélküli tanuláson alapuló, térbeli tevékenységekre vonatkozó következtetési módokat különböztethetünk meg (Liu et al., 2021).

A felügyelt tanuláson alapuló következtetési módszer lényege, hogy a térbeli és időbeli tartózkodást leíró adatokat címkézik (jelölik), tehát egyfajta nyelvi annotációval látják el, ami jelen esetben az aktivitás típusára vagy egyéb jellemzőire vonatkozik. Majd a gép ebből határozza meg az adott jellemző jegyeket, és ez szolgál majd a kiértékelés alapjául is, így pedig lehetséges következtetni a különböző tevékenységtípusokra. Az egyik leggyakrabban alkalmazott modellt a rejtett Markov-modell, amely a rejtett tevékenységi típusok meghatározására alkalmas (Loo et al., 2021).

A felügyelet nélküli tanuláson alapuló módszer képes következtetni az emberi tevékenységekre statisztikai valószínűség alapján (Widhalm et al., 2015). Ha az aktivitási adatok egy adott helyhez (lokációhoz) kapcsolódnak, ráadásul bizonyos – jellegzetes – időpontokhoz, akkor valószínűleg egy jellegzetes mindennapi tevékenységi színtér használatára utalnak. Például: ha 19 és 22 óra közötti időszakban viszonylag kisebb földrajzi területhez kötődnek, akkor az valószínűleg otthoni tevékenységekre utal. Ide tartoznak a valószínűségi grafikus modellek, melyeket tevékenységek klaszterezésére, a tevékenységek közötti függőségek modellezéséhez használnak. Az ilyen modellek figyelembe veszik a tevékenység típusát, illetve az érkezési időt és a tartózkodási időtartamot az egyes területhasználati típusokhoz kapcsolódóan (Liu et al., 2021).

A kutatási eredményeinkről szóló fejezet utolsó részében azt vizsgáljuk meg, hogy milyen szakpolitikai vonatkozásai vannak a mintánkba került tanulmányoknak. Adataink összhangban vannak azokkal a korábbi megállapításokkal, amelyek szerint a big data-módszerek egyre jelentősebb szerepet töltenek be a városfejlesztésben és -üzemeltetésben, így például a helyi szintű egészségügyi- és közlekedésszervezés vagy a területhasználati tervezés esetében (lásd pl. Wang et al., 2021).

Témaválasztásunk miatt a közlekedési fókuszú tanulmányok dominálnak a mintán belül, és e téren a big data alkalmazása igen széleskörű. Használják például közlekedési stratégiák vagy utazási előrejelzések kidolgozására, illetve valós idejű adatszolgáltatásra, mozgásminták tér- és időbeli elemzésére, autóbuszjáratok útvonalának és a taxiközlekedésnek az optimalizálására (Qu et al., 2019; Xia et al., 2021; Wang et al., 2020). Szintén gyakori, hogy az emberi mobilitás és az emberi viselkedés között megállapítható kapcsolat alapján igyekeznek előre jelezni a városi mozgásmintákat (Shi, 2019; Wang et al., 2021; Zhao et al., 2019). Továbbá, a big datát alkalmazó kutatások egy része forgalomtervezési céllal készült, például a torlódások számának csökkentésére a városi forgalom elemzése által (Zhao & Hu, 2019).

A területhasználatra vonatkozó adatok alkalmazására több példa is említhető a várostervezésben. A mintánkban szereplő kutatások egy részében a szerzők a területhasználat osztályozását az emberi

tevékenységi mintákkal vetik össze. Így előre jelzik a területhasználat változásait az emberi mobilitás és aktivitás jellemzői alapján, vagy feltárják a hétköznapi és a hétvégi területhasználat sajátosságait (Ren et al., 2019; Zhang et al., 2020). A területhasználat vizsgálata a közegészségügyben is megjelenik és a Covid19-járvány kapcsán tett intézkedések megalapozásában is szerepet játszik. Az emberi mobilitás mintázatának változásait különböző kategóriák szerint észlelik, mint például lakóhely, tömegközlekedés, bevásárlóközpontok, parkok, munkahelyek, és ezeken a területeken vizsgálják az emberi mobilitást és interakciókat. Mindebből pedig következtetéseket vonnak le az emberek viselkedésére a járvány alatt, amit például óvintézkedések kidolgozásához használnak fel (Jiang et al., 2021).

Szintén kiemelt szerepe van az egészségügyi vonatkozású cikkeknek a mintán belül. Az utóbbi években megnövekedett azoknak a kutatásoknak a száma, amelyek középpontjában a Covid19-járványhelyzet alatti vagy közvetlenül az utáni mobilitási mintázatok elemzése áll. Az ilyen tanulmányok eredményeit pedig gyakran kimondottan közegészségügyi felhasználásra, például járvány elleni védekezésre ajánlják a szerzők (Hasselwander et al., 2021). A Covid19 mellett azonban más egészségügyi kockázatok is megjelennek a mintában lévő közleményekben, például a lakossági mobilitás vizsgálata Ebola-járvány idején (Peak et al., 2018) vagy a Dengue vírus terjedésének térbeli és időbeli vizsgálata big data mobilitási adatok alapján (Kraemer et al., 2018). Megint más tanulmányokban a közegészségügyi intézményeket kategorizálták az alapján, hogy az intézmények és a betegek közötti térbeli interakció milyen kórházi jellemzőket tükröz (Kong et al., 2017).

Az elemzett tanulmányok egy másik csoportjára a fenntarthatósággal kapcsolatos szakpolitikai vonatkozások jellemzők. Az ilyen jellegű kutatások gyakran a fenntartható közlekedési eszközök, fenntartható közlekedési rendszer bevezetéséhez nyújtanak tudományos alapot, mint például az elektromos járművek használata vagy a taxi flotta villamosításának hatásai. Ide tartozik még az egyéni mobilitási rendszerek fenntarthatóságra irányuló átalakítása is (Li et al., 2017; Wang et al., 2021; Zhao et al., 2019). Egy másik releváns szakpolitikai téma az egyéni fenntartható mobilitási módok támogatása, mint a kerékpármegosztó szolgáltatások vagy a gyalogos közlekedés optimalizálása, aminek a célja az emisszió csökkentése a városban (Chen et al., 2020; Schmeller, 2021; Sevtsuk et al., 2021; Zhang et al., 2019).

Érdemes kiemelni azoknak a közleményeknek a csoportját, amelyek explicit módon kapcsolódnak az okos város (smart city) fejlesztési elképzeléshez, így akár több tématerületet is érinthetnek a fent felsoroltak közül. Az okos város fogalmi kérdéseivel e tanulmány keretein belül nem foglalkozunk, hiszen a témának bőséges nemzetközi és hazai szakirodalma van (pl. Sallai, 2018; Szalai, 2020; Szalai & Fabula, 2021), kutatásunk jellegzetességei miatt azonban érdemes néhány általános megállapítást tennünk.

A big data oldaláról nézve az okos város egyik fontos eleme, hogy a különböző szakterületek megoldásai egymást erősítve alkotnak egységes rendszert, melynek lényege a város erőforrásainak az optimális felhasználása. Az okos városra jellemző a valós idejű adatgyűjtés, az adatok elemzése, a városi infrastruktúra vezérlése, okos alkalmazások fejlesztése, ami segíti a magán- és közszolgáltatások

fejlesztését. Mindazonáltal nem szabad megfeledkezni arról sem, hogy okos városok kialakulásának mozgatórugói közül az adat és a technológiai fejlődés csak az egyik; legalább ilyen fontos elemek még a tervezésben megjelenő közösségi bevonás és a megfelelő szakpolitikai alkalmazás. Ami pedig a big data okosváros-tervezésben történő felhasználását illeti, elmondható, hogy az adatok nem kizárólag egy szolgáltatás (pl. telekommunikáció) melléktermékeként állnak elő, hiszen mind a közcélú (pl. tömegközlekedési operátorok), mind az üzleti szolgáltatók tervszerűen, célzottan gyűjtenek adatot operációs feladataik optimalizálása céljából. Ezeknek az adatoknak a városfejlesztési kiaknázásakor beszélhetünk másodlagos felhasználásról. E folyamatban az adatgazdák nem feltétlenül érdekeltek (pl. adatvagyon védelme, adatkezelési irányelvek miatt), ezért többnyire a közhatalmi pozícióból indított projektek lehetnek hatásosak. Az okos város megvalósítása tehát egy hatalmi harcoktól terhes folyamat, amelyben a szereplők közel sem azonos érdekek mentén és elhivatottsággal vesznek részt.

A mintánkon belül az okos városokkal kapcsolatos tanulmányok egy része az okos mobilitásszervezés jegyében különböző közlekedési módokra vonatkozó forgalomelemzéssel és -előrejelzéssel foglalkozik, például autóbusz- (Ho & Puspitasari, 2021), kötöttpályás (Taboada & Han, 2020), földalatti (Aqib et al., 2019), taxis (Naseer et al., 2021) vagy gyalogos közlekedés (Carter et al., 2020) vizsgálatával. Az intelligens közlekedési rendszer tervezéséhez kapcsolódnak még olyan témák, mint az emberek mobilitási mintázatainak elemzése az elektromos gépjármű-töltőállomások telepítési helyének optimalizálása (Wang et al., 2021) vagy a buszmegállók létesítése céljából (Fabbiani et al., 2018). A cikkek egy másik csoportjában az intelligens turizmusfejlesztés a fő szakpolitikai téma, például a turistákhoz kötődő mobilitási mintázatok elemzésével, keresőmotor-adatok (Gil et al., 2020), mobilcellaadatok (Park et al., 2020) vagy közösségimédia-adatok alapján (Encalada et al., 2017). Szintén érdemes kiemelni a területhasználattal foglalkozó tanulmányokat, amelyekben például zöldterület-használatot kutatnak crowdsourcing segítségével (Schrammeijer et al., 2021), vagy a kerékpározás és a területhasználat kapcsolatát elemzik kerékpármegosztók adatai alapján (Zhao et al., 2020) az intelligens városfejlesztés kontextusában.

A felsoroltak mellett több olyan téma is megjelenik az elemzett cikkekben a várostervezéssel kapcsolatban, amelyek a fentiekhez képest kisebb súllyal szerepelnek a mintában, mégis – jelenlegi vagy várható jövőbeli szerepük miatt – érdemes röviden írni róluk. Az egyik ilyen a rendszeroptimalizáció, amellyel kapcsolatban például a mobilcellaadatokat az egyéni mobilitási mintázat vizsgálatára használták 5G-alapú rádió-hozzáférési hálózat (RAN: Radio Access Network) működési költségének és szolgáltatásminőségének javítására (Chen et al., 2021). Szintén egyre növekvő jelentőségük miatt emeljük itt ki a különböző adatplatformok kérdéskörét. A bővülő – és egyre nagyobb mértékben hozzáférhető – adatmennyiség miatt ugyanis ezek fontossága nemcsak az üzleti szférában, hanem a városkutatásban és várospolitikában is erősödik. A városi mobilitás terén az ilyen platformot például arra használják, hogy az összegyűjtött, nagy adattömegnek minősített intelligens kártya- és jármű-helymeghatározási adatokat elemezzék a hatékonyabb közösségi közlekedés érdekében (Uçak et al., 2021). Végül vannak olyan kutatások, amelyekben a hálózatkutatás eszközeit alkalmazzák a mobil-

itással összefüggésben, például népességáramlási adatokat elemeznek utazási hálózatok (Zhang et al., 2021) vagy éppen a városszerkezet policentrikusságának feltérképezése végett (Wei et al., 2020).

## KÖVETKEZTETÉSEK

Tanulmányunk megírásával az volt a fő célunk, hogy megvizsgáljuk a big data jelentőségét a városi mobilitás kutatásában, ezért különböző kutatási kérdéseket tettünk fel, amelyeket a témával kapcsolatos nemzetközi szakirodalom szisztematikus áttekintésével válaszoltunk meg.

Az első kérdésünkkel arra kerestük a választ, hogy milyen mobilitási módok vizsgálatánál alkalmazták a big data-megközelítést és -módszereket a városi mobilitás kutatásában. A fő megállapításunk, hogy a big data a közösségi és egyéni közlekedés kutatásában is jelentős. Ennek oka, hogy az utóbbi években az okos eszközök és szenzorok elterjedése a városokban lehetővé tette a gyalogosok, kerékpárosok mobilitásának a vizsgálatát is, ugyanakkor a közösségi közlekedés vizsgálatának túlsúlyra figyelhető meg. Speciális közlekedési módnak tekinthető a taxi, amely szolgáltatáshoz ugyan többnyire személyautót használnak, de egyrészt ezek többsége alkalmas egyszerre több ember szállítására is, másrészt a taxiként szolgáló járművek gyakran egy-egy nagyobb társaság tulajdonához tartozó flottában működnek, ami lehetővé teszi a standardizált (okos) eszközökkel történő felszerelésüket és így a szervezett adatgyűjtést. Megállapítható, hogy egyes taxitársaságok jelenleg is gyűjtik és értékesítik a flottából gyűjtött lokációs adatokat, például navigációs szolgáltatóknak (TomTom).

Második kutatási kérdésünk lényege az volt, hogy a városi mobilitással kapcsolatos big data-tanulmányok megjelenésére milyen térbeli mintázat és időbeli dinamika jellemző (mely országokban és mikor jelentek meg). A fő megállapításunk, hogy a 2010-es évek eleje óta folyamatosan növekvő trend ugrásszerű gyarapodást mutat az elmúlt néhány évben. A növekedés lehetséges okaként megemlíthető, hogy egyre bővül az elérhető és tudományos célokra is felhasználható adatok köre, azok felhasználása végett pedig globálisan egyre nagyobb hangsúly kerül a digitalizációra. Mindez meghatározza az Európai Unió szakpolitikai törekvéseit, ugyanakkor a világ más centrumtársaságaiban, így az Amerikai Egyesült Államokban és Kínában is jelentős szereppel bír (lásd pl. Di Silvestre et al., 2018). A mintánkba került közlemények tanúsága szerint ezek a centrumtársaságok a big data felhasználásában is dominálnak.

Harmadik kutatási kérdésünk fókuszában az állt, hogy a mintában lévő tanulmányokban mekkora időintervallum és földrajzi lépték képezi a vizsgálat alapját. A kérdésre a válaszunk az, hogy a városi mobilitással kapcsolatos big data alkalmazása esetén a kutatási adatgyűjtési időintervallum egy naptól akár évekig is tarthat. Az adatgyűjtési időszak hossza pedig főként attól függ, hogy pontosan milyen adatokat használnak fel, illetve hogy milyen szakpolitikai célt szolgál az adott kutatás.

Negyedik kutatási kérdésünkkel arra koncentráltunk, hogy milyen adatforrásokat, adattípusokat és elemzési módszereket alkalmaznak a mintában szereplő egyes tanulmányok szerzői. A fő megállapításunk, hogy alapvetően három adattípusra támaszkodnak a kutatók. Ezek az adattípusok lehetnek felhasználó által létrehozott adatok, eszközök által gyűjtött adatok vagy forgalmi/tranzakciós adatok.

Megállapítható, hogy a technológia és az okoseszközök terjedésével egyre nagyobb arányban érhető el a lakosság, amely tovább javíthatja a big data kutatások pontosságát és jelentőségét a városi mobilitás kutatásában. A fent felsorolt adattípusokhoz kapcsolódó módszerek jellemzően a hagyományos statisztikai módszerek és a gépi tanulási módszerek csoportjaihoz köthetők.

Ötödik kutatási kérdésünk arra vonatkozott, hogy milyen szakpolitikai kapcsolódás mutatható ki az elemzett tanulmányokban. Ennek keretében számos jelentős témát azonosítottunk: fő kutatási célunkból (is) adódóan a legmarkánsabban a közlekedéstervezési és -szervezési kérdések jelennek meg a mintában, de szintén említésre méltó tématerületek a közegészségügyi és a területhasználat. Továbbá a településüzemeltetés fenti, „hagyományos” területein kívül lényegesnek tartottunk kiemelni olyan városkutatási és városfejlesztési paradigmákat és elképzeléseket, mint a fenntarthatóság vagy az okosváros, ugyanis a mintában szereplő tanulmányok között nagy számban voltak olyanok, amelyekben explicit módon hivatkoztak ezekre a szakpolitikai javaslatoknál.

Összességében megállapítható, hogy a big data-módszereket egyre szélesebb körben alkalmazzák a városi mobilitás vizsgálatában. Magyarországon azonban egyelőre viszonylag kis mértékben foglalkoznak ilyen típusú adatok felhasználásával (aminek nyilván vannak a kutatóktól független okai is, pl. az adatok elérhetősége, adatvédelmi irányelvek), bár kétségkívül egyre bővül a releváns tanulmányok köre. Érdemes tehát a jövőben nagyobb hangsúlyt fektetni erre a kutatási területre, például azért is, mert a várospolitikában a big data-módszerek és -eszközök szerepe egyre inkább felértékelődik a különböző kihívások megoldásában. Ugyanakkor szükséges figyelembe venni a big data és a digitalizáció negatív aspektusait és az egyes szakpolitikák kivitelezésének megfelelő módjait is (lásd pl. Creutzig et al., 2019; Pernestål et al., 2021).

Tanulmányunknak természetesen megvannak a maga korlátai, így számos olyan kutatási irány van, amelyen a jövőben érdemes lehet elindulni. Az egyik ilyen a jelenlegi szisztematikus szakirodalmi áttekintés bővítése több adatbázisra (pl. Web of Science), illetve többféle keresőkifejezésre (pl. Internet of Things, mobility network) vonatkozóan. Egy másik ilyen irány lehet a big data és a városi mobilitás kapcsolatának vizsgálatát kiterjeszteni, például a rendszeroptimalizációra, a hálózatkutatásra, a felhasználói élmény növelésére, az igényfelkeltésre vagy a különböző adatplatformok jellegzetességeire vonatkozóan. Reményeink szerint a fenti áttekintéssel sikerül elérnünk céljainkat, vagyis nemcsak bemutatni egy dinamikusan bővülő kutatási területet az érdeklődők számára, hanem inspirálni a magyarországi tudományos közösséget is.

## IRODALOMJEGYZÉK

Abduljabbar, R. L., Liyanage, S., & Dia H. (2021). The role of micro-mobility in shaping sustainable cities: A systematic literature review. *Transportation Research Part D: Transport and Environment*, 92, 102734, 1–12. <https://doi.org/10.1016/j.trd.2021.102734>

- Aqib, M., Mehmood, R., Alzahrani, A., Katib, I., Albeshri, A., & Altowaijri, S. M. (2019). Rapid Transit Systems: Smarter Urban Planning Using Big Data, In-Memory Computing, Deep Learning, and GPUs. *Sustainability*, 11(10), 2736. <https://doi.org/10.3390/su11102736>
- Bereczky Á. (2021). *Városi aktív- és mikromobilitás*. XXV. Nemzetközi Építéstudományi Konferencia – ÉPKO. <https://ojs.emt.ro/EPKO/article/view/541> (2022. 06. 15.)
- Bibri, S. E. (2021). Data-driven smart sustainable cities of the future: An evidence synthesis approach to a comprehensive state-of-the-art literature review. *Sustainable Futures*, 3, 100047. <https://doi.org/10.1016/j.sftr.2021.100047>
- Blais, P., Badard, T., Duchesne, T., & Côté, M-P. (2020). From Massive Trajectory Data to Traffic Modeling for Better Behavior Prediction in a Usage-Based Insurance Context. *ISPRS International Journal of Geo-Information*, 9(12), 722. <https://doi.org/10.3390/ijgi9120722>
- Bzdok, D., Altman, N.S., & Krzywinski, M. (2018). Points of Significance: Statistics versus machine learning. *Nature Methods*, 15(4), 233–234. <https://doi.org/10.1038/nmeth.4642>
- Candia, J., González, M.C., Wang, Pu., Schoenharl, T., Madey, G., & Barabási, A.-L. (2008). Uncovering individual and collective human dynamics from mobile phone records. *Journal of Physics A: Mathematical and Theoretical*, 41, 224015. <http://dx.doi.org/10.1088/1751-8113/41/22/224015>
- Carter, E., Adam, P., Tsakis, D., Shaw, S., Watson, R., & Ryan, P. (2020). Enhancing pedestrian mobility in Smart Cities using Big Data. *Journal of Management Analytics*, 7(2), 1–16. <https://doi.org/10.1080/23270012.2020.1741039>
- Chakravorti, B., Bhalla, A., & Chaturvedi, R.S. (2019). Which Countries Are Leading the Data Economy? <https://store.hbr.org/product/which-countries-are-leading-the-data-economy/H04R3C> (2022. 03. 08.).
- Chapple, K., Poorthuis, A., Zook, M., & Phillips, E. (2022). Monitoring streets through tweets: Using user-generated geographic information to predict gentrification and displacement. *Environment and Planning B: Urban Analytics and City Science*, 49(2), 704–721. <https://doi.org/10.1177/23998083211025309>
- Chen, F., Yin, Z., Ye, Y., & Sun, D. (2020). Taxi hailing choice behavior and economic benefit analysis of emission reduction based on multi-mode travel big data. *Transport Policy*, 97(1), 73–84.
- Chen, L., Jiang, Z., Yang, D., Wang, C., & Nguyen, T.-M.-T. (2021). Fog radio access network optimization for 5G leveraging user mobility and traffic data. *Journal of Network and Computer Applications*, 191, 103083. <https://doi.org/10.1016/j.jnca.2021.103083>
- Chua, A., Ow, S., Hsu, K., Yazhe, W., Chirico, M., & Zhongwen, H. (2020). Distilling actionable insights from big travel demand datasets for city planning. *Research in Transportation Economics*, 83, 100850. <https://doi.org/10.1016/j.retrec.2020.100850>
- Creutzig, F., Franzen, M., Moeckel, R., Heinrichs, D., Nagel, K., Nieland, S. & Weisz, H. (2019). Leveraging digitalization for sustainability in urban transport. *Global Sustainability*, 2, e14, 1–6. <https://doi.org/10.1017/sus.2019.11>

- Daniel, A., Subburathinam, K., Muthu, B.A., Rajkumar, N., Kadry, S., Mahendran, R.K., & Pandian, S. (2020). Procuring cooperative intelligence in autonomous vehicles for object detection through data fusion approach. *IET Intelligent Transport Systems*, 14(11), 1410–1417. <https://doi.org/10.1049/iet-its.2019.0784>
- Demertzis, M. (2021). The four pillars of a digital strategy. *Bruegel-Blogs*, 16 Mar. 2021. [link.gale.com/apps/doc/A655323022/AONE?u=szegedi&sid=googleScholar&xid=9f13c7f5](https://link.gale.com/apps/doc/A655323022/AONE?u=szegedi&sid=googleScholar&xid=9f13c7f5) (2022. 03. 09.)
- De Moya-Anegón, F., Chinchilla-Rodríguez, Z., Vargas-Quesada, B., Corera-Álvarez, E., Muñoz-Fernández, F. J., González-Molina, A., & Herrero-Solana, V. (2007). Coverage analysis of Scopus: A journal metric approach. *Scientometrics*, 73(1), 53–78. <https://doi.org/10.1007/s11192-007-1681-4>
- Di Silvestre, M. L., Favuzza, S., Sanseverino, E. R. & Zizzo, G. (2018). How Decarbonization, Digitalization and Decentralization are changing key power infrastructures. *Renewable and Sustainable Energy Reviews*, 93, 483–498. <https://doi.org/10.1016/j.rser.2018.05.068>
- Encalada, L.; Boavida-Portugal, I.; Cardoso Ferreira, C.; Rocha, J. (2017) Identifying Tourist Places of Interest Based on Digital Imprints: Towards a Sustainable Smart City. *Sustainability*, 9, 2317. <https://doi.org/10.3390/su9122317>
- Fabbiani, E., Nesmachnow, S., Toutouh, J., Tchernykh, A., Avetisyan, A., & Radchenko, G. (2018). Analysis of Mobility Patterns for Public Transportation and Bus Stops Relocation. *Programming and Computer Software*, 44(6), 508–525. <https://doi.org/10.1134/s0361768819010031>
- Felde, I., Nádai, L., Mezei, M., & Bognár, G. (2014). Characterization of urban traffic by using mobile phone traces. *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2014 January, 3360–3363. <https://doi.org/10.1109/smc.2014.6974446>
- Gan, Z., Yang, M., Feng, T., & Timmermans, H. (2018). Understanding urban mobility patterns from a spatiotemporal perspective: daily ridership profiles of metro stations. *Transportation*, 47(1), 315–336. <https://doi.org/10.1007/s11116-018-9885-4>
- Ge, P., He, J., Zhang, S., Zhang, L., & She, J. (2019). An Integrated Framework Combining Multiple Human Activity Features for Land Use Classification. *ISPRS International Journal of Geo-Information*, 8(2), 90. <https://doi.org/10.3390/ijgi8020090>
- Giglio, S., Bertacchini, F., Bilotta, E., & Pantano, P. (2020). Machine learning and point of interests: typical tourist Italian cities. *Current Issues in Tourism*, 23(13), 1646–1658. <https://doi.org/10.1080/13683500.2019.1637827>
- Gyarmati, P. (2019). Gondolatok a mesterséges intelligencia, gépi tanulás kapcsán. *Mesterséges Intelligencia*, 1(1), 31–39. <http://doi.org/10.35406/MI.2019.1.31>
- Hasselwander, M., Tamagusko, T., Bigotte, J. F., Ferreira, A., Mejia, A., & Ferranti, E. J. S. (2021). Building back better: The COVID-19 pandemic and transport policy implications for a developing megacity. *Sustainable Cities and Society*, 69, 102864. <https://doi.org/10.1016/j.scs.2021.102864>



- Ho, C.-Y., & Puspitasari, I. (2021). Intelligent Transportation Systems in Smart Cities Application to Taichung City Bus, Taiwan. *Advances in Decision Sciences*, 25(1), 143–166. <https://doi.org/10.47654/v25y2021i1p143-166>
- Hoseinzadeh, N., Liu, Y., Han, L. D., Brakewood, C., & Mohammadnazar, A. (2020). Quality of location-based crowdsourced speed data on surface streets: A case study of Waze and Bluetooth speed data in Sevierville, TN. *Computers, Environment and Urban Systems*, 83(2), 101518. <https://doi.org/10.1016/j.compenvurbsys.2020.101518>
- International Institute for Management Development [IMD] (2021). *IMD World Digital Competitiveness Ranking*. [https://www.imd.org/globalassets/wcc/docs/release-2021/digital\\_2021.pdf](https://www.imd.org/globalassets/wcc/docs/release-2021/digital_2021.pdf) (2022. 03. 08.)
- Jalali, R., Koochi-Fayegh, S., El-Khatib, K., Hoornweg, D., & Li, H. (2017). Investigating the Potential of Ridesharing to Reduce Vehicle Emissions. *Urban Planning*, 2(2), 26–40. <https://doi.org/10.17645/up.v2i2.937>
- Jeney, L., Hideg, É., & Tózsá, I. (2014) *Jövőföldrajz. A hazai gazdasági fejlődés területi és települési aspektusai a jelenben és a jövőben*. Gazdaságföldrajzi szakkönyvek. Budapesti Corvinus Egyetem.
- Jiang, Y., Huang, X., & Li, Z. (2021). Spatiotemporal Patterns of Human Mobility and Its Association with Land Use Types during COVID-19 in New York City. *ISPRS International Journal of Geo-Information*, 10(5), 344. <https://doi.org/10.3390/ijgi10050344>
- Kan, Z., Tang, L., Kwan, M-P., Ren, C., Liu, D., & Li, Q. (2019). Traffic congestion analysis at the turn level using Taxis' GPS trajectory data. *Computers, Environment and Urban Systems* 74, 229–243. <https://doi.org/10.1016/j.compenvurbsys.2018.11.007>
- Kim, M.-K., Kim, S., & Sohn, H.-G. (2018). Relationship between Spatio-Temporal Travel Patterns Derived from Smart-Card Data and Local Environmental Characteristics of Seoul, Korea. *Sustainability*, 10(3), 787. <https://doi.org/10.3390/su10030787>
- Kitchin, R. (2014). Big Data, new epistemologies and paradigm shifts. *Big Data & Society*, 1(1), 1–12. <https://doi.org/10.1177/2053951714528481>
- Kondor A. Cs., Szabó T., & Prorok M. (2020). Az egynapos látogatóforgalom elemzése mobilcella adatok alapján: esettanulmány Szentendre példáján. *Turizmus Bulletin*, 20 (Különszám), 19–28. <https://doi.org/10.14267/TURBULL.2020v20n4.2>
- Kong, L., Liu, Z., & Wu, J. (2020). A systematic review of big data-based urban sustainability research: State-of-the-science and future directions. *Journal of Cleaner Production*, 273(1), 123142. <https://doi.org/10.1016/j.jclepro.2020.123142>
- Kong, X., Liu, Y., Wang, Y., Tong, D., & Zhang, J. (2017). Investigating Public Facility Characteristics from a Spatial Interaction Perspective: A Case Study of Beijing Hospitals Using Taxi Data. *ISPRS International Journal of Geo-Information*, 6(2), 38. <https://doi.org/10.3390/ijgi6020038>
- Kovács, Z., Vida, Gy., Elekes, Á., & Kovalcsik, T. (2021). Combining Social Media and Mobile Positioning Data in the Analysis of Tourist Flows: A Case Study from Szeged, Hungary. *Sustainability*, 13(5), 2926. <https://doi.org/10.3390/su13052926>

- Kovalcsik, T., Vida, Gy., & Boros, L. (2021). A társadalomföldrajzi folyóiratok rangsorának alakulása a Scimago adatbázisa alapján. *Modern Geográfia*, 16(4), 49–68. <https://doi.org/10.15170/MG.2021.16.04.03>
- Kukely, Gy., Aba, A., & Fleischer, T. (2017). New framework for monitoring urban mobility in European cities. *Transportation Research Procedia*, 24, 155–162. <https://doi.org/10.1016/j.trpro.2017.05.081>
- Laakso, M., Welling, P., Bukvova, H., Nyman, L., Björk, B-C., Hedlund T. (2011). The Development of Open Access Journal Publishing from 1993 to 2009. *PLoS ONE*, 6(6), e20961. <https://doi.org/10.1371/journal.pone.0020961>
- Li, J., Xu, L., Tang, L., Wang, S., & Li, L. (2018). Big data in tourism research: A literature review. *Tourism Management*, 68, 301–323.
- Li, S., Lyu, D., Liu, X., Tan, Z., Gao, F., Huang, G., & Wu, Z. (2020). The varying patterns of rail transit ridership and their relationships with fine-scale built environment factors: Big data analytics from Guangzhou. *Cities*, 99, 102580. <https://doi.org/10.1016/j.cities.2019.102580>
- Li, W., Li, Y., Fan, J., & Deng, H. (2017). Siting of Carsharing Stations Based on Spatial Multi-Criteria Evaluation: A Case Study of Shanghai EVCARD. *Sustainability*, 9(1), 152. <https://doi.org/10.3390/su9010152>
- Liao, Y. (2021). Ride-sourcing compared to its public-transit alternative using big trip data. *Journal of Transport Geography*, 95, 103135. <https://doi.org/10.1016/j.jtrangeo.2021.103135>
- Lin, J., Wu, K., Yang, S., & Liu, Q. (2021). The Asymmetric Pattern of Population Mobility during the Spring Festival in the Yangtze River Delta Based on Complex Network Analysis: An Empirical Analysis of “Tencent Migration” Big Data. *ISPRS International Journal of Geo-Information*, 10, 582. <https://doi.org/10.3390/ijgi10090582>
- Liu, J., Li, J., Li, W., & Wub, J. (2016). Rethinking big data: A review on the data quality and usage issues. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 134–142. <https://doi.org/10.1016/j.isprsjprs.2015.11.006>
- Liu, S., Long Y., Zhang L., & Liu H. (2021). Semantic Enhancement of Human Urban Activity Chain Construction Using Mobile Phone Signaling Data. *ISPRS International Journal of Geo-Information*, 10(8), 545. <https://doi.org/10.3390/ijgi10080545>
- Loo, B. P. Y., Zhang, F., Hsiao, J. H., Chan, A. B., & Lan, H. (2021). Applying the Hidden Markov Model to Analyze Urban Mobility Patterns: An Interdisciplinary Approach. *Chinese Geographical Science*, 31(1), 1–13. <https://doi.org/10.1007/s11769-021-1173-0>
- Mamei, M., Biccocchi, N., Lippi, M., Mariani, S., & Zambonelli, F. (2019). Evaluating Origin–Destination Matrices Obtained from CDR Data. *Sensors*, 19(20), 4470. <https://doi.org/10.3390/s19204470>
- Melikov, P., Kho, J. A., Fighiera, V., Alhasoun, F., Audiffred, J., José L. Mateos, J. L., & González, M. C. (2021). Characterizing Urban Mobility Patterns: A Case Study of Mexico City. In W. Shi, M.F. Goodchild, M. Batty, M.P. Kwan & A. Zhang (Eds.), *Urban Informatics. The Urban Book Series*. (pp. 153–170). Springer. [https://doi.org/10.1007/978-981-15-8983-6\\_11](https://doi.org/10.1007/978-981-15-8983-6_11)

- Naseer, S., Liu, W., Sarkar, N.I., Shafiq, M. & Choi, J.-G. (2021). Smart City Taxi Trajectory Coverage and Capacity Evaluation Model for Vehicular Sensor Networks. *Sustainability*, 13(19), 10907. <https://doi.org/10.3390/su131910907>
- Nyitrai, T. (2021). A gépi tanulás módszereinek alkalmazása R-ben. *Statistikai Szemle*, 99(2), 173–198. <https://doi.org/10.20311/stat2021.2.hu0173>
- Pai, D., Triyason, T., & Padungweang, P. (2018). Big Data in Smart-Cities: Current Research and Challenges. *Indonesian Journal of Electrical Engineering and Informatics (IJEI)*, 6(4), 351–360. <https://doi.org/10.11591/ije.v6i1.543>
- Park, S., Xu, Y., Jiang, L., Chen, Z., & Huang, S. (2020). Spatial structures of tourism destinations: A trajectory data mining approach leveraging mobile big data. *Annals of Tourism Research*, 84, 102973. <https://doi.org/10.1016/j.annals.2020.102973>
- Patgiri, R., & Ahmed, A. (2016). *Big Data: The V's of the Game Changer Paradigm*. 2016 IEEE 18th International Conference on High Performance Computing and Communications; IEEE 14th International Conference on Smart City; IEEE 2nd International Conference on Data Science and Systems (HPCC/SmartCity/DSS). <https://doi.org/10.1109/hpcc-smartcity-dss.2016.0014>
- Peak, C.M., Wesolowski, A., Erbach-Schoenberg, E. z., Tatem, A.J., Wetter E., Lu, X., Power, D., Weidman-Grunewald, E., Ramos, S., Moritz, S., Buckee, C.O., & Bengtsson, L. (2018). Population mobility reductions associated with travel restrictions during the Ebola epidemic in Sierra Leone: use of mobile phone data. *International Journal of Epidemiology*, 47(5), 1562–1570. <https://doi.org/10.1093/ije/dyy095>
- Peng, Z., Bai, G., Wu, H., Liu, L., & Yu, Y. (2021). Travel mode recognition of urban residents using mobile phone data and MapAPI. *Environment and Planning B: Urban Analytics and City Science*, 48(9), 2574–2589. <https://doi.org/10.1177/2399808320983001>
- Pernestål, A., Engholm, A., Bemler, M. & Gidofalvi, G. (2021). How Will Digitalization Change Road Freight Transport? Scenarios Tested in Sweden. *Sustainability*, 13, 304. <https://doi.org/10.3390/su13010304>
- Pintér, G., Nádai, L., Bognár, G., & Felde, I. (2018). Evaluation of Mobile Phone Signals in Urban Environment during a Large Social Event. *IEEE 12th International Symposium on Applied Computational Intelligence and Informatics (SACI)*, 000247–000250. <https://doi.org/10.1109/SACI.2018.8440943>
- Pucci, P., & Vecchio, G. (2019). Big Data: Hidden Challenges for a Fair Mobility Planning. In P. Pucci, & G. Vecchio (Eds.), *Enabling Mobilities. Planning Tools for People and Their Mobilities*. (pp. 43–58). Springer. [https://doi.org/10.1007/978-3-030-19581-6\\_4](https://doi.org/10.1007/978-3-030-19581-6_4)
- Qu, Z., Wang, X., Song, X., Pan, Z., & Li, H. (2019). Location Optimization for Urban Taxi Stands Based on Taxi GPS Trajectory Big Data. *IEEE Access*, 7, 62273–62283. <https://doi.org/10.1109/ACCESS.2019.2916342>
- Raban, R.D., & Gordon, A. (2020). The evolution of data science and big data research: A bibliometric analysis. *Scientometrics*, 122(3), 1563–1581. <https://doi.org/10.1007/s11192-020-03371-2>

- Ren, M., Lin, Y., Jin, M., Duan, Z., Gong, Y., & Liu, Y. (2019). Examining the effect of land-use function complementarity on intra-urban spatial interactions using metro smart card records. *Transportation*, 47(4), 1607–1629. <https://doi.org/10.1007/s11116-019-09977-7>
- Rodríguez-Echeverría, J., Semanjski, I., Van Gheluwe, C., Ochoa, D., IJben, H., & Gautama, S. (2020). Density-Based Spatial Clustering and Ordering Points Approach for Characterizations of Tourist Behaviour. *ISPRS International Journal of Geo-Information*, 9(11), 686. <https://doi.org/10.3390/ijgi9110686>
- Ságvári, B. (2017). Társadalomtudomány a Big Data korában. *Statisztikai Szemle*, 95(5), 491-504. <https://doi.org/10.20311/stat2017.05.hu0491>
- Ságvári, B. (2019). Tér és társadalom Big Data szemüvegen keresztül. *Területi Statisztika*, 59(1), 27–48. <https://doi.org/10.15196/TS590102>
- Sallai, Gy. (2018). *Az okos város (Smart City)*. Dialóg Campus Kiadó.
- Schmeller, D. (2021). Taktikai városfejlesztés – Új gyakorlat megjelenése a városi zöldfelületek létrehozásában. *Modern Geográfia*, 16(1), 81–106. <https://doi.org/10.15170/MG.2021.16.01.05>
- Schrammeijer, E. A., van Zanten, B. T., & Verburg, P. H. (2021). Whose park? Crowdsourcing citizen's urban green space preferences to inform needs-based management decisions. *Sustainable Cities and Society*, 74, 103249. <https://doi.org/10.1016/j.scs.2021.103249>
- Sevtsuk, A., Basu, R., Li, X., & Kalvo, R. (2021). A big data approach to understanding pedestrian route choice preferences: Evidence from San Francisco. *Travel Behaviour and Society*, 25, 41–51. <https://doi.org/10.1016/j.tbs.2021.05.010>
- Shi, T. (2019). Spatial Data Mining and Big Data Analysis of Tourist Travel Behavior. *Ingénierie des Systèmes d'Information*, 24(2), 167–172. <https://doi.org/10.18280/isi.240206>
- Snyder, H., (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104(C), 333–339. <https://doi.org/10.1016/j.jbusres.2019.07.039>
- Sun, H., Chen, Y., Lai, J., Wang, Y., & Liu, X. (2021). Identifying Tourists and Locals by K-Means Clustering Method from Mobile Phone Signaling Data. *Journal of Transportation Engineering, Part A: Systems*, 147(10). <https://doi.org/10.1061/JTEPBS.0000580>
- Szalai, Á. (2020). Az okosváros-koncepció kritikai földrajzi vizsgálata – elméleti háttér és lehetséges kutatási irányok. *Tér és Társadalom*, 34(2), 88–107. <https://doi.org/10.17649/TET.34.2.3201>
- Szalai, Á., & Fabula, Sz. (2021). Az okos vidékfejlesztés lehetőségei és korlátai Magyarországon. *Modern Geográfia*, 16(1), 59–79. <https://doi.org/10.15170/MG.2021.16.01.04>
- Taboada, G. L., & Han, L. (2020). Exploratory Data Analysis and Data Envelopment Analysis of Urban Rail Transit. *Electronics*, 9(8), 1270. <https://doi.org/10.3390/electronics9081270>
- Tarcisio, B.P., Crease, R., Fisher, K.T., & Parsons, M. (2018). A Crack in the Automobility Regime? Exploring the transition of São Paulo to sustainable urban mobility. *Cities*, 107, 102914. <https://doi.org/10.1016/j.cities.2020.102914>
- Tettamanti, T., & Varga, I. (2014). Mobile Phone Location Area Based Traffic Flow Estimation in Urban Road Traffic. *Advances in Civil and Environmental Engineering*, 1(1), 1–15.

- Tikito, I., & Souissi, N. (2019). Meta-analysis of Systematic Literature Review Method. *International Journal of Modern Education and Computer Science*, 11(2), 17–25. <https://doi.org/10.5815/ijmecs.2019.02.03>
- Torre-Bastida, A.I., Serl, J.D., Laña, I., Maitena Ilardia, M., Bilbao, N.M., & Campos-Cordobés, S. (2018). Big Data for Transportation and Mobility: Recent Advances, Trends and Challenges. *IET Intelligent Transport Systems*, 12(8), 742-755. <https://doi.org/10.1049/iet-its.2018.5188>
- Tu, W., Cao, R., Yue, Y., Zhou, B., Li, Q., & Li, Q. (2018). Spatial variations in urban public ridership derived from GPS trajectories and smart card data. *Journal of Transport Geography*, 69(C), 45–57. <https://doi.org/10.1016/j.jtrangeo.2018.04.013>
- Uçak, E., Karagümüş, E., & Şener, C. (2021). A scalable platform for big data analysis in public transport. *Concurrency and Computation: Practice and Experience*. <https://doi.org/10.1002/cpe.6534>
- Vidović, K., Sostarić, M., & Budimir, D. (2019). An Overview of Indicators and Indices Used for Urban Mobility Assessment. *Traffic&Transportation*, 31(6), 703–714. <https://doi.org/10.7307/ptt.v31i6.3281>
- Wang, A., Zhang, A., Chan, E.H.W., Shi, W., Zhou, X., & Liu Z. (2021). A Review of Human Mobility Research Based on Big Data and Its Implication for Smart City Development. *ISPRS International Journal of Geo-Information*, 10(1), 13. <https://doi.org/10.3390/ijgi10010013>
- Wang, P., Lai, J., Huang, Z., Tan, Q., & Lin, T. (2020). Estimating Traffic Flow in Large Road Networks Based on Multi-Source Traffic Data. *IEEE Transactions on Intelligent Transportation Systems*, 22(9), 5672–5683. <https://doi.org/10.1109/tits.2020.2988801>
- Wei, L., Luo, Y., Wang, M., Cai, Y., Su, S., Li, B., & Ji, H. (2020). Multiscale identification of urban functional polycentricity for planning implications: An integrated approach using geo-big transport data and complex network modeling. *Habitat International*, 102134. <https://doi.org/10.1016/j.habitatint.2020.102134>
- Widhalm, P., Yang, Y., Ulm, M., Athavale, S., & González, M.C. (2015). Discovering urban activity patterns in cell phone data. *Transportation*, 42(4), 597–623. <https://doi.org/10.1007/s11116-015-9598-x>
- Wu, H., Liu, L., Yu, Y., Peng, Z., Jiao, H., & Niu, Q. (2019). An Agent-based Model Simulation of Human Mobility Based on Mobile Phone Data: How Commuting Relates to Congestion. *ISPRS International Journal of Geo-Information*, 8(7), 313. <https://doi.org/10.3390/ijgi8070313>
- Xia, D., Jiang, S., Yang, N., Hu, Y., Li, Y., Li, H., & Wang, L. (2021). Discovering spatiotemporal characteristics of passenger travel with mobile trajectory big data. *Physica A: Statistical Mechanics and Its Applications*, 578, 126056. <https://doi.org/10.1016/j.physa.2021.126056>
- Xie, G., Zhang, R., Li, Y., Huang, L., Wang, C.-D., Yang, H., & Liang, J. (2021). AttractRank: District Attraction Ranking Analysis Based on Taxi Big Data. *IEEE Transactions on Industrial Informatics*, 17(3), 1679–1688. <https://doi.org/10.1109/tii.2020.2994038>

- Xu, Y., Jiang, S., Li, R., Zhang, J., Zhao, J., Abbar, S., & Gonzalez, M. C. (2019). Unraveling environmental justice in ambient PM<sub>2.5</sub> exposure in Beijing: A big data approach. *Computers Environment and Urban Systems*, 75, 12–21. <https://doi.org/10.1016/j.compenvurbsys.2018.12.006>
- Xu, Y., Li, J., Xue, J., Park, S., & Li, Q. (2021). Tourism Geography through the Lens of Time Use: A Computational Framework Using Fine-Grained Mobile Phone Data. *Annals of the American Association of Geographers*, 111(5), 1420–1444. <https://doi.org/10.1080/24694452.2020.1812372>
- Yang, X., Tang, L., Zhang, X., & Li, Q. (2018). A Data Cleaning Method for Big Trace Data Using Movement Consistency. *Sensors*, 18(3), 824. <https://doi.org/10.3390/s18030824>
- Yang, Z., Gao, W., Zhao, X., Hao, C., & Xie, X. (2020). Spatiotemporal Patterns of Population Mobility and Its Determinants in Chinese Cities Based on Travel Big Data. *Sustainability*, 12(10), 4012. <https://doi.org/10.3390/su12104012>
- Yuan, Y., & Raubal, M. (2012). Extracting Dynamic Urban Mobility Patterns from Mobile Phone Data. In N. Xiao, M.P. Kwan, M.F. Goodchild, & S. Shekhar (eds.), *Geographic Information Science. GIScience 2012. Lecture Notes in Computer Science*. 7478. Springer. [https://doi.org/10.1007/978-3-642-33024-7\\_26](https://doi.org/10.1007/978-3-642-33024-7_26)
- Zeinab E., Wanggen W., José L.V.G., Ofelia C., & Li H. (2020). Analyzing Social-Geographic Human Mobility Patterns Using Large-Scale Social Media Data. *ISPRS International Journal of Geo-Information*, 9(2), 125. <https://doi.org/10.3390/ijgi9020125>
- Zhang, X., Sun, Y., Zheng, A., & Wang, Y. (2020). A New Approach to Refining Land Use Types: Predicting Point-of-Interest Categories Using Weibo Check-in Data. *ISPRS International Journal of Geo-Information*, 9(2), 124. <https://doi.org/10.3390/ijgi9020124>
- Zhang, Y., Lin, D., & Liu, X. C. (2019). Biking islands in cities: An analysis combining bike trajectory and percolation theory. *Journal of Transport Geography*, 80, 102497. <https://doi.org/10.1016/j.jtrangeo.2019.102497>
- Zhao, P., & Hu, H. (2019). Geographical patterns of traffic congestion in growing megacities: Big data analytics from Beijing. *Cities*, 92, 164–174. <https://doi.org/10.1016/j.cities.2019.03.022>
- Zhao, R., Yang, L., Liang, X., Guo, Y., Lu, Y., Zhang, Y., & Ren, X. (2019). Last-Mile Travel Mode Choice: Data-Mining Hybrid with Multiple Attribute Decision Making. *Sustainability*, 11(23), 6733. <https://doi.org/10.3390/su11236733>
- Zhao, Y., Lin, Q., Ke, S. & Yu, Y. (2020). Impact of land use on bicycle usage: A big data-based spatial approach to inform transport planning. *Journal of Transport and Land Use*, 13(1), 299–316. <https://doi.org/10.5198/jtlu.2020.1499>
- Zhou, J., & Murphy, E. (2019). Day-to-day variation in excess commuting: An exploratory study of Brisbane, Australia. *Journal of Transport Geography*, 74(C), 223–232. <https://doi.org/10.1016/j.jtrangeo.2018.11.014>

Zhu, Z., Sun, L., Chen, X., & Yang, H. (2021). Integrating probabilistic tensor factorization with Bayesian supervised learning for dynamic ridesharing pattern analysis. *Transportation Research Part C: Emerging Technologies*, 124, 102916. <https://doi.org/10.1016/j.trc.2020.102916>

#### Internetes források

- [1] Az Európai Parlament és a Tanács (EU) 2021/1060 rendelete (2021. június 24.). <https://eur-lex.europa.eu/legal-content/HU/TXT/PDF/?uri=CELEX:32021R1060&from=EN> (2022. 06. 15.)
- [2] THE NEW EUROPEAN Urban Mobility Framework (2021. december 14.). [https://ec.europa.eu/commission/presscorner/detail/en/fs\\_21\\_6781](https://ec.europa.eu/commission/presscorner/detail/en/fs_21_6781) (2022. 06. 15.).

*Ez a mű a Creative Commons Nevezd meg! – Ne add el! – Ne változtasd! 4.0 nemzetközi licence-feltételeinek megfelelően felhasználható. (CC BY-NC-ND 4.0)*

<https://creativecommons.org/licenses/by-nc-nd/4.0/>

*This open access article may be used under the international license terms of Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 (CC BY-NC-ND 4.0)*

<https://creativecommons.org/licenses/by-nc-nd/4.0/>

