

OTDK-dolgozat

2023

BUDAPESTI CORVINUS EGYETEM
KÖZGAZDASÁGTUDOMÁNYI KAR

A VAGYONOS LAKOSSÁG SPILLOVER HATÁSAI MAGYARORSZÁGON

**TERÜLETI AUTOKORRELÁCIÓ AZ EGY ADÓZÓRA JUTÓ SZEMÉLYI
JÖVEDELEMADÓ- ALAPOT KÉPEZŐ JÖVEDELEM JÁRÁSI SZINTŰ ADATAIBAN**

SPILLOVER EFFECTS OF A WEALTHY POPULATION IN HUNGARY

**SPATIAL AUTOCORRELATION IN RESIDENTIAL INCOME PER CAPITA AT THE SUB-
COUNTY LEVEL**

Készítette:

Bátki Benedek

Kiss Eszter Borbála

Konzulens: Madari Zoltán

2022.12.30.

Absztrakt

Kutatásunkban a magyarországi vagyoni szegregáció járási szintű alakulását vizsgáljuk 2018-as és 2012-es adatokat összevetve. Munkánkban arra a kérdésre keressük a választ, hogy a járások közötti vagyoni különbségek – melyet az egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem változó jelenít meg – milyen erősen csoportosulnak a térben, mennyiben magyarázhatók releváns magyarázóváltozókkal (munkaerőpiaci, demográfiai ismérvekkel), illetve mennyire lelhető fel ezen változókra való kontrollálás után is területi autokorreláció adatainkban. Ha a releváns változók nem képesek feloldani a területi csoportosulások tényét a járások gazdagsága terén, akkor kutatásunk szerint ebben az esetben vagyoni „spilloverek” léteznek járások között, mivel nincs más fellelhető ok a helyi különbségek adott módon való alakulására a térbeli elhelyezkedésen kívül. Egy ilyen eredmény azt jelentené, hogy a vagyoni szegregáció folyamatosan újratermeli magát bármely más tényezőtől függetlenül. Ezen térbeli elkülönülés megmagyarázhatósága kardinális kérdés, mivel megmutatja, hogy mely tényezők mentén segíthető elő a vagyoni olló zárása Magyarországon. Vizsgálatainkat a területi ökonometria eszköztárával kivitelezük, globális és lokális Moran statisztikák számolásával, hőtésképek készítésével, valamint területi autoregresszív modellek építésével. Eredményeinkben azt találjuk, hogy nem kielégítően magyarázhatók demográfiai és munkaerőpiaci mutatókkal a járások közötti vagyoni különbségek – és az ezekre való kontrollálás után nem tűnik el az erős területi autokorreláció adatainkból, amelyet első vizsgálataink során találtunk. Ebből arra következtetünk, hogy nem csupán erős területi elkülönülés található az adatokban, de ez részben vagyoni spillover-hatások következménye, nem kizárólag olyan gazdasági és társadalmi folyamatoké, melyek jól definiálhatók és amelyek kellő kormányzati akarattal enyhíthetők.

Kulcsszavak: vagyoni spillover hatások, járások gazdagsága, területi autokorreláció

JEL klasszifikáció: C21, P25

Tartalomjegyzék

Absztrakt.....	i
1. Bevezetés.....	1
2. A társadalmi egyenlőtlenségek kialakulásának okai Magyarországon	2
3. A területi autokorreláció vizsgálatának módszertani összefoglalója.....	4
4. A magyar járási szintű adatok elemzése	8
5. Összefoglalás.....	19
6. Irodalomjegyzék.....	22
7. Melléklet.....	23

Táblázatjegyzék

1. táblázat: A Moran-I statisztika értékei különböző súlymátrixok esetén, 2018-ban és 2012-ben.	12
2. táblázat: A 2018-as adatokon futtatott OLS modell eredményei.....	15
3. táblázat: A 2012-es adatokon futtatott OLS modell eredményei.....	15
4. táblázat: A SAR modell output eredményei 2nd neighbors súlymátrixszal, 2018	18
5. táblázat: A SAR modell output eredményei a 35 km-es súlymátrixszal, 2012	18

Ábrajegyzék

1. ábra: Személyi jövedelemadó-alapot képező jövedelem (zöld), a száz lakásra jutó lakos (narancssárga), a tartósan munkanélküliek aránya (piros), belföldi vándorlási különbözet (piros-kék) 2012-ben (jobb) és 2018-ban (bal).	9
2. ábra: A Moran pontdiagram az egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem esetén (2018 bal, 2012 jobb).	13
3. ábra: A lokális Moran statisztika hő térképe egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem esetén 35 km-es súlymátrixszal (2018 bal, 2012 jobb).	14
4. ábra: Az OLS modell maradékváltozójának hő térképe (2018 bal, 2012 jobb).	16
5. ábra: A Moran plot az OLS regresszió hibatagjával (2018 bal, 2012 jobb).	17

1. Bevezetés

A járásek közötti vagyoni különbségek a közbeszédben is fontos témák Magyarországon, a szegregációval, oktatással, lehetőségekkel, elvándorlással gyakran együtt merülnek fel. De mi okozhatja a vagyoni szegregációt? Mennyire erős ez a jelenség, mivel lehetne enyhíteni? Ezen kérdések foglalkoztattak minket is akkor, amikor kutatásunkat elkezdttük. Munkánkban az alábbi kérdésekre keressük a választ 2018-as és 2012-es járási szintű adatok segítségével:

Az egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem (melyet egy adott területi egység lakosainak vagyonosságára utaló változóként kezelünk)

K1: mennyire erősen különül el területi dimenzió mentén,

K2: mennyiben magyarázható egyéb releváns magyarázóváltozókkal,

K3: mennyiben magyarázható saját környezete lakosainak gazdagságával?

Ezen vizsgálatokat területi ökonometriai módszerekkel végezzük el, területi autokorrelációs mérőszámokkal, valamint SAR modellek építésével. Kutatásunkban a területi hasonlóságok hatástávolságát is megkíséreljük feltérképezni különböző távolságmátrixok alkalmazásával.

Kutatásunk az alábbi módon épül fel: a második fejezetben a releváns szakirodalmat tekintjük át, ebből tájékozódva fontos vagyoni szegregációt okozó potenciális változók köréről. A harmadik fejezetben bemutatjuk az általunk használt eljárások elméleti háttérét: a globális és lokális Moran próbák és Moran pontdiagramok értelmezését, használatát, valamint a SAR modellek építésének módját, feltételeit. A negyedik fejezetben ismertetjük empirikus eredményeinket, melyeket utolsó, ötödik fejezetünkben értelmezünk, valamint itt vonjuk le konklúzióinkat kutatási kérdéseinkkel kapcsolatban.

2. A társadalmi egyenlőtlenségek kialakulásának okai Magyarországon

Jelen fejezetben a dolgozatunkat megalapozó releváns szakirodalmat mutatjuk be, valamint ezek segítségével alátámasztjuk az általunk vizsgált kérdéskör aktualitását és fontosságát.

A lakóhelyi és területi szegregáció, valamint ezek következményei már a múlt évszadban is foglalkoztatta a kutatókat. Duncan és Duncan (1973) szerint a földrajzi távolság kapcsolatban lehet a társadalmon belüli különbözőséggel. Kiemelik, hogy e két különböző, de mégis egymással összefüggő mutató között szorosabb kapcsolat áll fent a nagyvárosok tekintetében. Egy úgynevezett disszimilaritási indexet alkalmaztak, amely a különböző foglalkozási csoportokba tartozó lakosok arányát használja fel. Ezen index kiszámítása, egy adott rész és a teljes egész között megadja a szegregációs mutatót. Számunkra ez fontos lehet, mivel ha a foglalkozási csoportok területileg jól elkülönülnek nem csak egy város, hanem annak agglomerációjában is, akkor ez hatással lehet a jövedelmek területi eloszlására.

Kertesi és Kézdi (2005) a hazai oktatási rendszert vizsgálta meg, azon belül is az általános iskolai hálózatban végbemenő szegregációs folyamatokat. Ezen folyamatok egyenlőtlenséget okozhatnak szociálisan, és szerintük a hátrányos helyzetű gyerekek alacsonyabb színvonalú oktatásban részesülnek, amely mélyítheti az egyenlőtlenségeket. Azt találták, hogy Magyarországon erősebb a kapcsolat a szülők nyújtotta tanítás és oktatás, valamint a gyerekek iskolai teljesítménye között, mint a fejlett országok esetében.

Czirfusz (2015) szintén a területi egyenlőtlenségeket kutatta, de mindezt egy közfoglalkoztatási megközelítésből. Kitér az úgynevezett *workfare* államra, amely a munkához köti a jóléti juttatásokat és nagy hangsúlyt fektet magára a munkavégzési kötelezettségre. Ezen állami szakpolitika képes arra, hogy újabb társadalmi-térbeli egyenlőtlenségeket generáljon. Elemzésében településenként vizsgálta meg a közfoglalkoztatás hazai helyzetét, amely alapján elmondható, hogy megyén belül is jelentős különbségek vannak a közfoglalkoztatási lehetőségek terén. Az is megfigyelhető, hogy a népesebb és több munkanélkülivel rendelkező nagyvárosok esetén az ezen foglalkoztatásban dolgozók száma relatíve kevesebb. Konklúziója, hogy az elmúlt évtizedben folytatott közfoglalkoztatási átalakítások következtében újabb térbeli egyenlőtlenségek alakultak ki a munkaerőpiac terén. A program jogszabályi részére kitérve megemlíti, hogy az abban leírtak csak részlegesen valósultak meg – a munkanélküliség szempontjából legrosszabb helyzetű térségek támogatása az elsődleges – 2011 és 2013 között. Ez a rendszer tehát nem ellensúlyozza, hanem elmélyíti a térbeli egyenlőtlenségeket.

Nagy és szerzőtársai (2015) a magyar vidéki térségekre helyezték a hangsúlyt, részletesebben vizsgálva ezen területek marginalizációs folyamatait. Kiemelik, hogy szoros kapcsolatban áll egymással a társadalmi marginalizálódás és a térbeli hátrányok kialakulása, valamint ez a folyamat tovább súlyosbíthatja a rurális térségek helyzetét. Ezen helyzet rákényszeríti az ott élőket, hogy a megszokott keretek között folytassák életüket, így csökkentve a társadalmi előrelépés esélyét. Elemzésük során azt találták, hogy az egyenlőtlenségek újratermelődésében jelentős szerepet játszanak a piaci gyakorlatok, valamint az állami intézmények döntései is. Ezen intézmények célja, hogy a hazai, különböző dimenziójú egyenlőtlenségeket ellensúlyozzák, azonban ezt nem tudták megvalósítani a különböző kezdeményezésekkel, programokkal és strukturális átalakításokkal. Összességében elmondható, hogy a vidéki térségben élő gazdasági és társadalmi szereplők nem képesek kitörni a hátrányos helyzetből, mivel egyrészt ők is hozzájárulnak napi gyakorlataikkal a marginalizálódáshoz, másrészt nincsenek biztosítva a kellő és szükséges lokális, illetve globális lehetőségek.

Csité és Németh (2007) szintén a hazai kistérségeket vizsgálta meg, fókuszálva az életminőség területi autokorrelációjára. Proxy változóként az emberi fejlődés indexét alkalmazták (HDI), melynek kapcsán megemlíti annak előnyeit – nemzetközi összehasonlítás lehetősége, valamint hátrányait is, amely pont az imént említett jellemzőjéből ered, hiszen elsősorban az országok közti összehasonlításra használatos. Elemzésüket az 1994-es, a 2001-es és a 2005-ös év esetében végezték el, és így a mutatók dinamikáit is képesek voltak megvizsgálni. A HDI mutató komponenseit külön-külön is lemodellezték és arra jutottak, hogy a kistérségek fejlettségi szintje ezek függvényében is változik. Az iskolázottság esetében figyelhető meg a legkedvezőbb kép, míg a jóléti helyzet jelentősebb egyenlőtlenségeket mutat. A 7, illetve 4 éves időintervallum esetében is erősödő pozitív autokorrelációt azonosítottak. Ez a trend betudható a főváros agglomerációjának felzárkózására, valamint Borsod-Abaúj-Zemplén és Szabolcs-Szatmár-Bereg megyék jelentős elmaradottságának és az ott kialakuló depressziós övezeteknek, melyek jelen elemzésünkben is jól kirajzolódnak. Kutatásuk eredményeként elmondható, hogy a kistérségek közötti egyenlőtlenségek ugyan mérséklődtek, de a nagyobb közigazgatási egységek (megyék) között nem figyelhető meg ez a javulás.

Szakálné és szerzőtársai (2018), hasonlóan Kertesi és Kézdi (2005) tanulmányához, a magyar oktatást vizsgálta meg. A tudástársadalom és az információs igények bővülésének okán a felsőfokú végzettségűek területi eloszlását helyezték kutatásuk középpontjába. Módszertanuk egy részét az általunk is alkalmazott Moran-index, illetve lokális Moran-index építette fel, melyek segítségével meg tudták vizsgálni, hogy van-e szabályszerűség a diplomások

eloszlásának térbeli dimenziójában. Három évre (1990, 2001 és 2011) és három térfelosztási szintre (település, kistérség, megye) nézve mérték meg a területi hasonlóság mértékét és mind a három területi szintre elmondható, hogy javuló a tendencia az egyenlőtlenségek esetében. Ezt a kiegyenlítődési folyamatot elsősorban a települések közötti, valamint a megyék közötti kiegyenlítődés indukálta. Az is kijelenthető, hogy az aránybéli javulás nagyrészt a felsőfokú intézményekkel ellátott kistérségek esetében következett be.

3. A területi autokorreláció vizsgálatának módszertani összefoglalója

A járási szintű egy adózóra jutó személyi jövedelemadó-alapot képező jövedelmi adatokon végzett modellezéssel a vagyoni szintű területi elkülönülés erősségét és okait kívántuk vizsgálni. Ilyen kérdésekhez megfelelő eszközt nyújtanak térökonometriai eljárások, melyek indokoltságát, módszertani alapjait és az általunk használt elemeit ebben a fejezetben mutatjuk be.

A legalapvetőbb lineáris regressziós eljárások alkalmazásának egyik általános feltevése, hogy a mintába kerülő elemek egymástól statisztikailag függetlenek. A területi adatokban (például járási és megyei szintű gazdasági, demográfiai adatokban) azonban sokszor megfigyelhető a függetlenség helyett területi függőség. Ekkor az i -edik területi egység eredményváltozó értéke nem csupán a magyarázóváltozók i -edik területnél felvett értékeitől függ, hanem az i -edik területtel szomszédos j -edik területen felvett értékétől is. Ha figyelmen kívül hagyjuk ezt a kapcsolatot és így építünk regressziót adatainkra, a becsléseink torzítottak és inkonzisztensek lesznek (LeSage, 2008). Ez a szimultán adatgeneráló folyamat az alábbi módon formalizálható (LeSage & Pace, 2009, p. 2.):

$$y_i = \alpha_i y_j + X_i \beta + \varepsilon_i$$

$$y_j = \alpha_j y_i + x_j \beta + \varepsilon_j$$

$$\varepsilon_i \sim N(0, \sigma^2) \quad i = 1$$

$$\varepsilon_j \sim N(0, \sigma^2) \quad j = 2$$

Tobler írásához kötődik azon empirikus megfigyelés stilizált tényekhez hasonló „törvényben” való lefektetése, miszerint minden összefügg mindennel, azonban a közeli dolgok erősebben függenek egymástól, mint a távoli dolgok (Tobler, 1970, p. 236). Az adatokban rejlő területi korreláltságnak számos oka lehet, például olyan általunk nem megfigyelt változók, melyek hasonlóan alakulnak az egymáshoz közel fekvő területek között, vagy spillover-ek gazdasági, infrastrukturális és kulturális ismérvek mentén egyik területi régióból a hozzá közeli régiókba

(LeSage, 2008). Kutatásunk esetén mi is azt próbáltuk feltérképezni, hogy a szomszédos járások esetén hasonlóan alakuló egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem oka inkább a releváns változók hasonlósága egymáshoz közel fekvő területek esetén, vagy ezekre kontrollálva is marad szignifikáns területi autokorreláció az adatokban és így vagyoni spillover-hatásokról beszélhetünk. Értelmezésünk szerint a legerősebb vagyoni szegregációra utaló jel az utóbbi eset lenne, ekkor ugyanis kormányzati szempontból tekintve a vagyoni szegregáció enyhítését, nem lenne elegendő gazdasági, társadalmi területeken kiegyenlítő intézkedéseket hozni, hanem kompenzálni kell az olyan folyamatokat is, amelyek a gazdagsági spillover-hatásokból származnak.

A területi módszertan két területére fókuszálunk munkánkban, globális és lokális területi autokorrelációs próbafüggvényekre és tesztstatisztikákra, illetve a területi autokorrelációval kiegészített regresszióra (SAR modell). Előbbiek lényege megvizsgálni, hogy van-e területi autokorreláció a vizsgált változóban, utóbbié pedig feltárni ennek meghatározó erejét akkor, amikor egyéb releváns magyarázóváltozók alakulását és hatását is figyelembe vesszük.

Ahhoz, hogy ezeket vizsgálni tudjuk, tisztáznunk kell, hogy miképpen formalizáljuk a területek közötti „közelséget”. A súlymátrixok leírását Varga (2002) átfogó munkájára támaszkodva foglaljuk össze ebben a bekezdésben. A térbeli pozíciókat és közelségeket térbeli súlymátrixokkal tudjuk kifejezni, melyek minden terület közötti kapcsolatot jelölnek. A mátrix oszlopai és sorai a megfigyelt területekhez rendelhetők, a mátrix elemei pedig két terület közötti távolság vagy szomszédág jellemzése számmal. A mátrix fődiagonálisában 0 érték szerepel, ugyanis az itt elhelyezkedő elemek reprezentálják a területi egység önmagával való szomszédságának megnyilvánulását, konvenció szerint pedig a terület önmagával nem szomszéd. A mátrixok lehetnek szomszédságon alapulók, tehát nulla érték szerepel ott, ahol két terület nem közvetlenül szomszédos egymással, 1 érték szerepel ott, ahol a két terület szomszédos. A mátrixok lehetnek távolságon alapulók, ahol a mátrix a területi egységek egymástól való távolságának négyzetének reciprokjait tartalmazza (tehát egy adott terület minél távolabb van a vizsgált területtől, annál kisebb a súlya egy SAR modellben a magyarázóváltozók között). A bináris szomszédságmátrixok és a távolságmátrixok keveréke egy olyan bináris mátrix, amely adott távolságig (például kilométerben megadva) 1, azon túli távolság esetén 0 értéket vesz fel. A távolságmátrixok esetén szokványos a sorstandardizálás, mely a Maximum Likelihood becslésekhez szükséges (ugyanis OLS becslést nem használhatunk az eredményváltozó térbeli késleltetettjeinek magyarázóváltozóként való alkalmazása esetén annak hibataggal való korrelálása miatt), ilyenkor a sorokban szereplő

értékeket elosztjuk az adott sorösszeggel. A súlymátrixok határozzák meg, hogy az adott vizsgált területi egység esetén a többi terület felvett értékei mekkora súllyal számítsanak a próbafüggvényekben, regressziókban.

Hasonló értékek térbeli csoportosulásakor pozitív területi autokorrelációról, erős váltakozó mintázat esetén (magas értékek mellett alacsony értékek) negatív területi autokorrelációról beszélünk. Könnyen ábrázolhatjuk Moran pontdiagram segítségével, hogy mintánkra melyik típusú térbeli kapcsolat jellemző. LeSage (2008) alapján röviden összefoglalva: a Moran pontdiagram x tengelye mutatja eredményváltozó felvett értékeit, az y tengely pedig ugyanezen változó térbeli késleltetettjeinek átlagos értékét. Minden megfigyelést tartalmazni fog az eredményváltozó átlaga és a térbeli késleltetettjeinek átlagos értékeinek átlaga által felosztott sík valamelyik negyede; az alapján látjuk majd, hogy pozitív vagy negatív autokorrelációról beszélünk az adatokban, hogy mely negyedekben helyezkednek el leggyakrabban a pontok, és hogy a pontokra illesztett egyenes meredeksége pozitív (tehát pozitív területi autokorreláció) vagy negatív-e (negatív területi autokorreláció). Ha az első (harmadik) negyedben helyezkedik el a pontok nagy része, az azt jelenti, hogy az átlagosnál nagyobb (kisebb) eredményváltozó értékekhez az átlagosnál nagyobb (kisebb) térbeli késleltetett értékek tartoznak, tehát pozitív területi autokorreláció van jelen az adatainkban. Ha a második (negyedik) negyedbe esik a pontok jelentős része, akkor az átlagosnál kisebb (nagyobb) eredményváltozó értékekhez átlagosnál nagyobb (kisebb) térbeli késleltetett értékek tartoznak, negatív területi autokorreláció van jelen a megfigyelésekben. A pontokra illesztett (OLS) egyenes meredeksége a Moran-I statisztikával lesz egyenlő, amelyet a következő bekezdésben mutatunk be.

A Moran-féle I statisztika bemutatásakor Varga (2002), az Anselin-féle lokális Moran-próba bemutatásakor Anselin (1995) munkájára támaszkodunk. Az említett két statisztika között az a különbség, hogy az előbbi az összes megfigyelést vizsgálva próbálja megállapítani, hogy jellemző-e általában a mintára valamilyen területi autokorreláció, az utóbbi pedig az egyes megfigyelések esetén vizsgálja a környezetük figyelembevételével területi autokorreláció jelenlétét. A pozitív tesztstatisztikák pozitív, a negatív tesztstatisztikák negatív területi autokorrelációt jelentenek. A Moran-I próba képlete Varga (2002) alapján:

$$I = \frac{N}{S_0} \cdot \frac{\sum_i \sum_j w_{ij} \cdot (x_i - \mu) \cdot (x_j - \mu)}{\sum_i (x_i - \mu)^2}, \quad (1)$$

ahol w_{ij} az i és j területek kapcsolatának súlya, x_i az i -edik terület vizsgált változójának felvett értéke, μ a vizsgált változó várható értéke, N a megfigyelések száma, S_0 pedig a súlyok összege (normalizáló faktor), amely sorstandardizált mátrixok esetén N . A fentebbi képlet kifejezése

hasonlít a két véletlen változó közötti korreláció kifejezésére, innen ered a területi autokorreláció elnevezés. Amennyiben lokális térbeli autokorrelációt akarunk vizsgálni, ezt az Anselin-féle lokális Moran-I statisztikával tehetjük meg, melynek képlete Anselin (1995) alapján:

$$I_i = (x_i - \mu) \cdot \sum_j w_{ij}(x_j - \mu), \quad (2)$$

ahol I_i az i -edik megfigyeléshez tartozó lokális Moran érték, w_{ij} az i és j területek területi kapcsolatának súlya, x_i az i -edik terület vizsgált változójának felvett értéke, μ a vizsgált változó várható értéke. Anselin (1995) tanulmányának célja bemutatni, hogy a globális területi autokorrelációt jellemző tesztstatisztikák hogyan bonthatók fel az egyes területi megfigyeléseik ezen tesztstatisztikákhoz való hozzájárulásaira. Hasonló módon, ha (2) egyenlet I_i értékeit összegezzük i mentén, visszakapjuk az (1) egyenletben szereplő globális I tesztstatisztikát.

A területi autokorreláció másik általunk használt módszertani területe a SAR modell, melynek elméleti leírását LeSage (2008) munkája alapján foglaljuk össze. Fentebb már leírtuk, hogy az eredményváltozóban található területi függőség indokolja a SAR modell használatát, és azt, hogy egy ilyen modellnél nem tudunk OLS becslést alkalmazni, mivel sérülne az eredményváltozó területi késleltetettjeinek magyarázóváltozóként való alkalmazása miatt a szigorú exogenitás. Most bemutatjuk az alapvető regressziós modell felépítését, amelyet Maximum Likelihood becsléssel fogunk alkalmazni. Az egyenlet LeSage (2008) alapján:

$$\mathbf{y} = \rho \mathbf{W} \mathbf{y} + \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad (3)$$

ahol $\mathbf{y}$ az eredményváltozó vektor, $\mathbf{X}$ a magyarázóváltozók mátrixa, $\boldsymbol{\beta}$ az együtthatók vektora, $\boldsymbol{\varepsilon}$ a nulla várható értékű, konstans varianciájú, normális eloszlású hibatag vektor (a Maximum Likelihood becslés feltétele normális eloszlása), $\mathbf{W}$ az eredményváltozó területi késleltetettjeinek sorstandardizált súlymátrixa, ρ pedig a korrelációs skalár, amely a területi autokorrelációs kapcsolat átlagos szorosságát írja le. A spillover hatások megjelenése vélhetően nem azonnal történik, így potenciális új vizsgálati terület lehet majd a gazdagság területi terjedésének időbeli dinamikája is. LeSage és Pace (2009) kitér az időbeli és keresztmetszeti területi modellek mögötti megfontolásokra. Amennyiben olyan jelenséget vizsgálunk, amely a vizsgált időegységek mentén érdemben nem változik, úgy tekinthetünk egy darab keresztmetszetre úgy, mint az időbeli folyamat hosszú távú kimenetelére vagy egy egyensúlyi állapotra. Ezen megfontolásból összehasonlítjuk a 2018-as adatokat a 2012-es adatokkal, figyelmet fordítva a változókban és kapcsolatokban való érdemi eltérésekre, módszertani vizsgálataink azonban mindkét esetben keresztmetszetiek. A következő fejezetben az ebben a

módszertani összefoglalóban tárgyalt technikák gyakorlati alkalmazását is bemutatjuk, miközben ismertetjük kutatásunk eredményeit.


4. A magyar járási szintű adatok elemzése

Adatainkat a KSH 2012-es, illetve 2018-as járási szintű adattábláiból vettük (KSH Területi Statisztikai Évkönyv, 2012; KSH Területi Statisztikai Évkönyv, 2018).


Elemzésünkben először a 2018-as adatokat vizsgáltuk, majd ugyanazokat a vizsgálatokat, modellezéseket elvégeztük a 2012-es adatokon, hogy összevethessük az eredményeket. Eredményváltozónk az egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem, melyet egy adott járás lakosai gazdagságának leírására alkalmasnak tekintünk. Magyarázóváltozóink az ezer lakosra jutó adózók száma, a lakosságszám, a 65 év feletti (2012-es adatokban adatelérhetőségi okokból 60 év feletti) aránya a járás állandó népességéből, a 180 napnál hosszabb ideje munkát keresők (tartósan munkanélküliek) aránya a munkavállalási korú állandó népességéből, a száz lakásra jutó lakók száma, az ezer lakosra jutó működő vállalatok száma és a belföldi vándorlási különbözet. A budapesti kerületeket eltávolítottuk a megfigyelésekből, mivel a főváros esetén véleményünk szerint mind a vagyoni dinamikában, mind a szomszédos területekkel való interakciókban jelentősen különböző folyamatok érvényesülnek az ország többi részéhez képest. A budapesti adatokat eltávolítva 174 megfigyelésünk van. Adathiánnyal a választott változók esetén egyszer, 2012-ben találoztunk: a Belpátfalvai járás esetén a KSH nem közölte a belföldi vándorlási különbözetet, mivel pedig 174 egység esetén egyetlen adat imputálása nem okoz számottevő torzítást, ezért a teljes összehasonlíthatóság érdekében a járás 2012-es belföldi vándorlási különbözetét a megye (Heves) többi járásának erre vonatkozó értékeinek átlagával helyettesítettük.

Hő térképek segítségével figyeltük meg területi szinten a tendenciákat az egyes változók esetén, ezek az 1. ábrán, illetve a Mellékletben megtekinthetők.


Száz lakásra jutó lakosok száma, 2018




Az egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem, 2018




Száz lakásra jutó lakosok száma, 2012



Az egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem, 2012





1. ábra Személyi jövedelemadó-alapot képező jövedelem (zöld), a száz lakásra jutó lakos (narancssárga), a tartósan munkanélküliek aránya (piros), belföldi vándorlási különbözet (piros-kék) 2012-ben (jobb) és 2018-ban (bal).

Saját szerkesztés.

Az 1. ábrán elhelyezett hőtérképeken megnézhetjük eredményváltozónk alakulását térben és 2012-ről 2018-ra is elrendeződés szempontjából¹, amelyen látjuk, hogy a Budapest környéki agglomerációk, illetve Északnyugat-Magyarország járásaiban legmagasabb az egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem, mely tendencia nem változott 2012-ről 2018-ra. Megnézhetjük azt is, hogy mely változók rajzolnak ki az eredményváltozóhoz hasonló térbeli mintázatot. A száz főre jutó lakás rendkívül érdekes változó, mivel a Budapest környéki agglomerációkban, gazdag területeken is magas az értéke, ugyanakkor szegényebb, északkeleti régiókban is. Ez a kettősség 2012-ről 2018-ra csak erősödött, a két időpont közötti időben még jobban közelítette a budapesti agglomeráció ezen változó mentén a keleti régió egyes járásait. A tartósan munkanélküliek aránya ellentétesen változik eredményváltozónkkal a hőtérkép alapján (amely mintázatban nem látszódik szignifikáns változás 2012 és 2018 között), a belföldi vándorlási különbség pedig látszólag jól leköveti az eredményváltozó alakulását – ez is logikus lehet, ha feltételezünk egy jelentős vagyoni önszelekciót, melynek keretében mindenki a gazdagabb környékekre próbál költözni (vagy a jó környék miatt, vagy amiatt, hogy egy környék azért gazdag, mert jó munkalehetőségek veszik körül) egészen jövedelme határáig. (2012-ről 2018-ra itt egyértelműen látszik a színskálák mintázatának megvizsgálása után, hogy az észak-keleti régiókból való elvándorlás fokozódott, a nyugati régiókba való vándorlás pedig enyhén mérséklődött.)

A Mellékletben megvizsgálva a többi változó két időpont közötti területi mintázatát, egyedül az 1000 állandó lakosra jutó működő vállalatok számában történt számottevő változás, itt a Nyíregyházi és Debreceni járások, melyek 2012-ben is kiemelkedtek régiójukban felfelé, még jobban elszakadtak és közelítették a nyugat-magyarországi régiók egyes járásainak értékét.

Ezeket figyelembe véve, a területi megoszlások terén legtöbb esetben beszélhetünk egyfajta állandósult állapotról, mely nem mutat számottevő változásokat. Ebből kifolyólag elvi hiba nem lenne egy darab keresztmetszet vizsgálatával a továbbiakban (természetesen a 2012 és 2018 közötti időszakhoz észszerűen közel), viszont a hőtérkép alapú megállapításaink megerősítése vagy megcáfolása végett továbbra is külön-külön vizsgáljuk a 2018-as és 2012-es adatokat.

A területi autokorrelációt eredményváltozónk esetén többek között globális Moran-I-vel vizsgáltuk. Többféle súlymátrix mellett is kiszámoltuk a tesztstatisztikát, egy szomszédsági

¹ Ne vonjunk le következtetéseket a két időpont közötti színváltozásokból, ugyanis változnak maguk az értékek, így ugyanaz az érték más szint kaphat 2018-ban és 2012-ben. Jelen összehasonlítás lényege a térbeli mintázat változásának eldöntése, főként az egyensúlyi állapottal kapcsolatos konklúziók levonásaképpen.

mátrixot, valamint 35, 40, 45, 50, 55 kilométeres bináris távolságmátrixot² hasonlítottunk össze. Ez azért hasznos, mert így a területi kapcsolatok természetéről, illetve azok hatástávolságáról is tudunk információhoz jutni.

Az eredményeket az 1. táblázat tartalmazza (mindegyik tesztstatisztika bármilyen szokásos szignifikancia szint mellett szignifikánsnak tekinthető permutációs teszt alapján).

1. táblázat: A Moran-I statisztika értékei különböző súlymátrixok esetén, 2018-ban és 2012-ben.

Saját szerkesztés.

Súlymátrix	Globális Moran-I tesztstatisztika 2018-ban	Globális Moran-I tesztstatisztika 2012-ben
Szomszédsági mátrix	0.577 (2.2e-16)	0.538 (2.2e-16)
35 kilométeres bináris távolságmátrix	0.584 (1.534947e-35)	0.551 (6.050135e-32)
40 kilométeres bináris távolságmátrix	0.577 (4.166121e-48)	0.545 (3.651757e-43)
45 kilométeres bináris távolságmátrix	0.556 (1.642362e-59)	0.519 (2.953401e-52)
50 kilométeres bináris távolságmátrix	0.545 (1.817178e-69)	0.508 (1.063699e-60)
55 kilométeres bináris távolságmátrix	0.523 (1.693084e-78)	0.485 (7.215681e-68)


Mind 2012-ben, mind 2018-ban számottevő területi autokorrelációról árulkodnak az adatok³. Minden súlymátrix esetén a 2018-as tesztstatisztika nagyobb értéket vesz fel a 2012-es párjánál. Ez a két időpont közötti vagyoni alapú területi elkülönülés fokozódását jelenti. A legnagyobb tesztstatisztika az adott évben mindkét esetben a 35 km-es bináris távolságmátrixhoz tartozik. Ez egyrészt a többi távolságalapú mátrixhoz viszonyítva azt jelenti, hogy a területi összefonódások és vagyoni hasonlóságok 35 km-es sugárban a legegységesebbek és legerősebbek. Másrészt a szomszédságmátrixhoz viszonyítva azt jelenti, hogy kevésbé az határozza meg a járások közötti vagyoni hasonlóságokat, hogy melyik két terület van egymáshoz a legközelebb, hanem az, hogy mi a járások tágabb területi egysége, járások vagy „szegényebb” zónába tartoznak, vagy „gazdagabb” zónába. Az 55 km-es bináris súlymátrix

² Az adott járásokhoz koordináta központokat rendeltünk, azok alapján járások közötti távolságokat számoltunk, végül az adott kilométer alatti távolságok esetén a közeli mátrixnak 1 súlyt, afölöttinek 0 súlyt adtunk.

³ A Moran-I statisztika elméleti határa 1 és -1, várható értéke tökéletes területi autokorrelálatlanság esetén $\frac{-1}{N-1}$.

esetén a nemnulla súlyok átlaga már 14.18, a maximális nemnulla súlyok száma pedig 25. Ezt túl sok kapcsolatnak ítéljük meg egy darab területi egység esetén az érdemleges vizsgálatokhoz, ezért a továbbiakban ezen súlymátrixot elhagyjuk vizsgálatainkból. (Mivel a 35 km-es súlymátrix mellett kapjuk a legnagyobb területi autokorrelációt, ezért a továbbiakban ezzel számolt eredményeinket tüntetjük fel.)


A területi autokorreláció irányáról meggyőződhetünk a Moran pontdiagram segítségével, amely a második ábrán látható (a 35 km-es súlymátrixszal számolva). Az illesztett egyenes meredeksége pozitív, amelyről már fentebb is említettük, hogy megegyezik a Moran-I statisztika értékével. Ebből a meredekségből (és a tesztstatisztika előjeléből) lehet megállapítani, hogy pozitív területi autokorreláció van jelen. Az ábrán az is látszik, hogy bár az illesztett egyenes meredeksége pozitív, de van több olyan megfigyelés, amelynek a környezetében az eredményváltozó és annak területi késleltetettjeinek átlaga ellentétesen mozog a meredekség által implikált egyirányú változáshoz képest (azaz a pontok a második és negyedik síknegyedben helyezkednek el, ez lokálisan negatív területi autokorrelációt jelent) – éppen ezért lokális Moran statisztikát is számolunk, hogy megnézzük, hol találhatunk ilyen megfigyeléseket.



2. ábra: A Moran pontdiagram az egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem esetén (2018 bal, 2012 jobb).

Saját szerkesztés.

Az Anselin-féle lokális Moran statisztikát értelmezni legegyszerűbben szintén hőtérkép segítségével lehet, ez a 3. ábrán található. A hőtérképen a halványnarancssárga színek, amelyek a nulla körüli értéket jelölik (tehát nincs szignifikáns lokális területi autokorreláció), töltik ki a hőtérképek jelentős részét. (A szinte fehér megfigyelések jelentik a 0 alá eső tesztstatisztikát, tehát a negatív területi autokorrelációt. A p-érték eredmények alapján 2018-ban csupán két járás esetén szignifikáns a negatív tesztstatisztika: a Debreceni és Tiszaújvárosi járások esetén. A Debreceni járás esetén ennek oka, hogy a járás felfelé emelkedik ki gazdagságban a környező egységek közül, a Tiszaújvárosi járás pedig lefelé lóg ki a környezetében.) Budapest



3. ábra: A lokális Moran statisztika hő térképe egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem esetén 35 km-es súlymátrixszal (2018 bal, 2012 jobb).

Saját szerkesztés.

agglomerációinál, különösképpen a nyugatiaknál, valamint 2018-ban az északkeleti járásokban látszik szignifikáns pozitív lokális területi autokorreláció. Ahogy Anselin (1995) megállapítja, a lokális Moran-I tesztstatisztikák azt mutatják, hogy az egyes területi egységek a globális I tesztstatisztikához hogyan járulnak hozzá. A két hő térképen látszik, hogy a területi autokorreláció nem egyenletes az országban, a Budapest körüli, északnyugat-magyarországi és északkelet-magyarországi járások esetén sokkal erősebb mértékben van jelen, mint az ország többi részén. Ezek a régiók felelnek a legnagyobb mértékben a vagyoni hasonlóságok területi koncentrációjáért.

A SAR modell megépítése előtt megvizsgáljuk, hogy indokolt-e egyáltalán a területi késleltetett alkalmazása a modellben – ha ugyanis sima lineáris regresszió alkalmazásakor a reziduumban nem marad területi autokorreláció, úgy nem feltétlenül indokolt további területi autokorrelációs módszertanok alkalmazása.

Kétféle eljárás segítségével építünk lineáris regressziót és szelektálunk a magyarázóváltozók között a 2018-as adatok esetén, amely modellt a 2012-es adatokon is alkalmazzuk (a 2012-es adatok esetén való optimalitástól függetlenül, mivel célunk a két időpont eredményeinek összevetése). Az elsőnél Akaike információs kritérium alapján backward szelekciós eljárást használunk, a másik eljárásban pedig LASSO modellt építünk és megvizsgáljuk, mely változók együttthatóit nem zsugorítja az eljárás nulla értékűre. Mindkét eljárás esetén ugyanazzal a szaturált modellel kezdünk, az egy adózóra jutó személyi jövedelemadó-alapot képező jövedelmet magyarázzuk az ezer lakosra jutó adózók számával, a 65 év feletti (2012-es adatok esetén 60 év feletti) arányával az állandó népességben, a tartós munkanélküliek

arányával, a száz lakásra jutó lakosok számával, az ezer lakosra jutó működő vállalkozások számával, a lakosságszámmal, valamint a belföldi vándorlási különbözettel.

2. táblázat: A 2018-as adatokon futtatott OLS modell eredményei.

Saját szerkesztés.

Koefficiensek neve	Koefficiensek	Standard hiba	t-statisztika értéke	p-érték
Tengelymetszet	-728.24	4.38e+02	-1.663	0.0981
1000 lakosra jutó adózók	4.20	7.82e-01	5.372	2.58e-07
Tartós munkanélküliség	-35.32	1.47e+01	-2.408	0.017
100 főre jutó lakások	2.55	7.34e-01	3.470	0.00066
1000 főre jutó működő vállalkozások száma	8.79	1.49e+00	5.896	2.01e-08
Lakosságszám	1.91e-03	4.85e-04	3.929	0.00013
Belföldi vándorlási különbözet	-13.21	2.78e+00	4.752	4.32e-06
$R^2 = 0.75$	Korrigált $R^2 = 0.74$			

3. táblázat: A 2012-es adatokon futtatott OLS modell eredményei.

Saját szerkesztés.


Koefficiensek neve	Koefficiensek	Standard hiba	t-statisztika értéke	p-érték
Tengelymetszet	167.67	3.21e+02	0.523	0.602
1000 lakosra jutó adózók	0.18	5.86e-01	0.305	0.760
Tartós munkanélküliség	-35.96	7.32e+00	-4.916	2.10e-06
100 főre jutó lakások	4.65	6.498e-01	7.159	2.46e-11
1000 főre jutó működő vállalkozások száma	7.48	1.35e+00	5.526	1.24e-07
Lakosságszám	0.0014	3.93e-04	3.446	0.00072
Belföldi vándorlási különbözet	-0.54	3.16e+00	-0.172	0.864
$R^2 = 0.71$	Korrigált $R^2 = 0.7$			

Mindkét eljárás során ugyanazt a „best subset” változócsoporthoz jutunk, melyek a 2. és 3. táblázatban is szerepelnek. Az OLS modell magyarázóereje 0.75 2018 esetén és 0.7 2012 esetén. 2018 esetén minden változó szignifikáns, a tartós munkanélküliség kivételével minden

szokásos szignifikancia szinten (a tartós munkanélküliség esetén csupán 5%-os szignifikancia szinten). 2012 esetén az 1000 lakosra jutó adózók száma, valamint a belföldi vándorlási különbség nem szignifikánsak.


A kutatás célja nem előszörban azt boncolgatni, hogy mely változó hatása milyen mértékű és milyen irányú, hanem eldönteni, hogy egy racionálisnak és teljeskörűnek tekinthető változói kontrollcsoport mellett is marad-e területi autokorreláció az adatokban, tehát a vagyoni különbségeknek van-e egy olyan része, mely csak a területek térbeli elhelyezkedésére vezethető vissza. A változók véleményünk szerint megfelelnek a racionális és teljeskörű kontrollok feltevésnek: szerepelnek benne munkakeresletből adódó vagyoni lehetőségek (működő vállalkozások száma), a lakosság gazdasági aktivitásának mértékéből adódó lehetőségek (adózók száma), a tartós munkanélküliséghez köthető állandósult szegénység vagy társadalmi leszakadás miatti hátráltató tényezők, a belföldi vándorlásból fakadó munkaerő kínálati többlet, illetve kontroll lakosságszám esetén (hogy a gazdag és népes járások ne torzítsanak).

A legfontosabb változókkal futtatott OLS modellek maradéktagjaiban meg kell vizsgálnunk a területi autokorrelációt, hogy megnézzük, indokolt-e SAR modell építése. Ahogy látszik a 4. ábra hő térképein, illetve az 5. ábra Moran pontdiagramjain az illesztett egyenes pozitív meredekségeiből ($\text{Moran-}I_{2018,35\text{km}}=0.334$; $\text{Moran-}I_{2012,35\text{km}}=0.349$), 35 km-es súlymátrixot alkalmazva még maradt rövid távolságon területi autokorreláció a hibatagban, az OLS



4. ábra: Az OLS modell maradékváltozójának hő térképe, (2018 bal, 2012 jobb).

Saját szerkesztés.



5. ábra: A Moran plot az OLS regresszió hibatagjával (2018 bal, 2012 jobb).

Saját szerkesztés.

becslések így torzítottak és inkonzisztensek. A SAR modell építése tehát indokolt 2012-es és 2018-as adatokon is.

Ugyanazon magyarázóváltozókkal, melyeket az OLS regresszióban is alkalmaztunk, SAR modellt építettünk, Maximum Likelihood becslést alkalmazva. A SAR modellt mindkét időpontban több súlymátrixszal is lefuttattuk, keresve az optimálisat, mely esetén eredményeink teljesítik a legfontosabb modellkritériumokat és minimális Akaike értéket adó modellhez vezetnek. A 2012-es adatok esetén az optimális súlymátrix a 45 km-es volt. A 2018-as esetén azonban egyik távolságmátrix és az elsőfokú (közvetlen) szomszédságmátrix esetén sem maradt modellünk hibatagja területi autokorreláció nélkül, mely sértette volna a modellfeltevéseket. Ezért új távolságmátrixot definiáltunk, másodfokú szomszédokat (a közvetlen szomszédok közvetlen szomszédjai) is bevettünk a területi kapcsolatok közé. (Ekkor is valamivel 1% alatti az LM-statisztikához tartozó p-érték, mi azonban ezzel az eredménnyel most megelégszünk, mivel nincs egyszerűen kivitelezhető eljárás, mellyel ez a hiba jelen tanulmány keretében kiküszöbölhető lenne.) A ML-becslés miatt fontos a SAR modell eredményváltozójának és reziduumának normalitása, melyet Shapiro-Wilk és Kolmogorov-Smirnov teszt, illetve QQ-plot segítségével is vizsgáltunk mindkét esetben. Eredményváltozónk, mint a vagyonnal kapcsolatos változók általában, erősen jobbra elnyúló eloszlást mutat, mely a hibatagban is megmutatkozik, az utóbbiról készült QQ-plot a magasabb értékeknél erősen elhajlik a normalitást jelző egyenestől. A statisztikai tesztek is nemnormalitást jeleznek. Eredményváltozónkat ezért a SAR modellek esetén logaritmáltuk, azonban ez a rho és a többi magyarázóváltozó koefficiensének értékén és szignifikanciáján érdemben nem változtatott. (A 4. és 5. táblázat a logaritmált eredményváltozó esetén kapott eredményeket mutatja.) Az így módosított modell esetén is elutasítja a két statisztikai teszt a

hibanormalitást, azonban a QQ-plot jelentős mértékben javult, pár outlier miatt hajlik csak el a magas, pozitív reziduum értékek esetén.

4. táblázat: A SAR modell output eredményei 2nd neighbors súlymátrixszal, 2018.

Saját szerkesztés.

<i>Koefficiensek neve</i>	<i>Koefficiensek</i>	<i>Standard hiba</i>	<i>z-statisztika értéke</i>	<i>p-érték</i>
<i>Tengelymetszet</i>	2.674	5.31e-01	5.033	4.82e-07
<i>1000 lakosra jutó adózók</i>	0.0012	6.69e-01	4.101	4.11e-05
<i>Tartós munkanélküliség</i>	-0.0135	1.25e+01	-1.972	0.0487
<i>100 főre jutó lakások</i>	0.00053	6.11e-01	2.93	0.0034
<i>1000 főre jutó működő vállalkozások száma</i>	0.0029	1.24e+00	6.308	2.83e-10
<i>Lakosságszám</i>	9.59e-07	4.06e-04	5.902	3.59e-09
<i>Belföldi vándorlási különbözet</i>	0.0013	2.48e+00	0.808	0.4191
LM test for residual autocorrelation				
		Rho	LR statisztika	p-érték
	5.0921 (0.024)	0.58	56.459	5.74e-14

5. táblázat: A SAR modell output eredményei a 35 km-es súlymátrixszal, 2012.

Saját szerkesztés.

<i>Koefficiensek neve</i>	<i>Koefficiensek</i>	<i>Standard hiba</i>	<i>z-statisztika értéke</i>	<i>p-érték</i>
<i>Tengelymetszet</i>	2.42054	5.31e-01	5.0333	4.82e-07
<i>1000 lakosra jutó adózók</i>	0.00072	2.75e-04	4.2699	1.95e-05
<i>Tartós munkanélküliség</i>	-0.00505	5.16e-03	-2.6124	0.00899
<i>100 főre jutó lakások</i>	0.00148	2.49e-04	2.1116	0.03472
<i>1000 főre jutó működő vállalkozások száma</i>	0.00416	5.06e-04	5.6354	1.75e-08
<i>Lakosságszám</i>	8.87e-07	1.6688e-07	5.7491	8.97e-09
<i>Belföldi vándorlási különbözet</i>	-0.00349	1.0264e-03	1.2568	0.20884
LM test for residual autocorrelation				
		Rho	LR statisztika	p-érték
	1.5677 (0.22232)	0.55	58.426	2.11e-14

A szignifikáns magyarázóváltozók előjelei mindkét időpontban hasonlóan alakulnak az OLS modelléhez, bár valamennyivel kevesebb változó tekinthető szignifikánsnak a területi késleltetett bevétele után. A területi késleltetethez figyelemfelkeltően magas rho érték tartozik (bár ezt a korrelációs tagot nem szabad a hagyományos értelemben vett korrelációval egyformán értelmezni), amely azt jelenti, hogy a magyarázóváltozókra való kontrollálás után az eredményváltozóban valóban jelentős területi autokorreláció marad.

A különböző statisztikai eljárások és adattranszformálások révén megbizonyosodhattunk arról, hogy itt kapott eredményeink megbízhatóak. Eredményeinket az összefoglalóban értelmezzük.

5. Összefoglalás

Eredményeink alapján az alábbiakat állapíthatjuk meg: élesen elkülönülnek egymástól területileg a vagyonosabb lakosú járások és a szegényebb járások. Ezt a globális, valamint lokális Moran-I indexekkel és a hő térképeken kirajzolódó területi mintázatokkal tudjuk alátámasztani. Továbbá, a meghatározó területi különbségek mind a vagyonosság, a munkanélküliség, az elvándorlás, a tartós munkanélküliségi ráta esetén megjelennek, ugyanis minden változó, de az említettek különösképpen relatíve változatlanok 2012 és 2018 között. Ezen eredmény alapján levonhatjuk azt a következtetést, hogy a demográfiai, szociális és gazdasági folyamatok és ezek különböző kimeneteleinek következményeképp a területi klasztereződés egyfajta egyensúlyi állapotban van, stabilan létezik Magyarországon.

A területi elkülönülés (területi autokorreláció) a járási szinten azonban nem egységesen jellemzi a teljes országot. Két fő övezet van, mely az általunk kapott közepesen erős pozitív területi autokorrelációt mutató globális Moran-I tesztstatisztika értéket jelentősen növeli: Budapest agglomerációja, valamint a nyugati agglomerációhoz közel fekvő járások, illetve Északkelet-Magyarország. Elvértve találunk csak olyan területeket, melyeket lokálisan statisztikailag szignifikáns negatív területi autokorreláció jellemez.

A globális Moran-I indexeket különböző súlymátrixokkal számolva arra az eredményre jutottunk, hogy a nyers, egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem járási szintű adataiban egy rövidebb, 35 kilométeres hatástávolságú kapcsolat figyelhető meg. Ilyen súlyozás esetén a megfigyelt területi autokorreláció nem csupán az ennél nagyobb távolságokkal generált mutatókhoz képest volt erősebb, hanem az egyszerű szomszédsági mátrixon alapuló mérésekhez képest is. Ebből arra következtethetünk, hogy nem csupán az explicit szomszédsági kapcsolatok, és ebből adódó gyors spillover-folyamatok miatt csoportosulnak a hasonló vagyonosságú járások a térben. Inkább egy általános szegényebb

vagy gazdagabb zónába tartozás az, amely a területi autokorrelációt jellemzi. Emellett persze fontos megjegyezni, hogy a 35 kilométeres távolság is relatíve kis területi csoportokat határoz meg.

A kutatás egyik kardinális pontja annak a kérdésnek a megválaszolása, hogy a területi klasztereződés vagyoniosság mentén magyarázható-e megfelelően releváns demográfiai, szociális és gazdasági változókkal, melyek könnyen értelmezhető módon növelik egy járás lakosainak gazdagságát. Nagy különbség van ugyanis aközött, hogy a járás lakosainak vagyoniosságát olyan változók alakítják, melyek közeli területeken hasonlóan alakulnak, illetve aközött, hogy pusztán adott járások lakosainak vagyoniossága számunkra nem érthető vagy kvantifikálható módon, spillover hatások által felfelé húzza a szomszédos vagy közeli járások lakosainak átlagos gazdagságát.

Különös figyelmet fordítottunk arra, hogy megvizsgáljuk azt, valóban léteznek-e ezek a nehezen mérhető spillover-hatások. Eredményeink egyértelműnek tűnnek. Miután az egy adózóra jutó személyi jövedelemadó-alapot képező jövedelem járási alakulásánál OLS-regresszió keretében kontrolláltunk többek között a tartós munkanélküliségre, az adózó lakosok számára, a lakosságszámra, a belföldi vándorlási különbözetre, azt találjuk, hogy továbbra is fennmarad egy jelentős erősségű területi autokorreláció az adatokban, bár gyengébbnek bizonyul, mint a kontrollálás előtt. Ez alapján kijelenthető, hogy a területi klasztereződést legalább részben meg tudjuk magyarázni. Ez egybevág az általunk is hivatkozott szakirodalommal. Kertesi és Kézdi (2005) munkája bizonyítékot hozott a közoktatási szegregációs folyamatokra (melyek vélhetően összefüggenek a munkanélküliség alakulásával, amikor az iskolai szegregáció elszenvedői kilépnek a munkaerőpiacra). Czirfusz (2015) a közfoglalkoztatás területi egyenlőtlenségeit fedezte fel, mely megmagyarázható okozója lehet a területi vagyoni különbségeknek. Nagy és szerzőtársai (2015) a rurális területen való szociális mobilitás hiányában vélték felfedezni a területi egyenlőtlenségek okait. Szakálné és szerzőtársai (2018) pedig a magasan képzett munkaerő területi eloszlását kutatva találtak egyenlőtlenségeket. Az általunk választott magyarázóváltozók is feltehetően vagy proxyk a szakirodalomban említett jelenségekre, vagy együtt járnak azokkal, bár kapcsolódásuk áttételes. Mindkét esetben azonban alkalmasak a jelenségekre való kontrollálásra.

Kutatásunk oly módon járul hozzá a szakirodalomhoz, hogy rávilágít arra, ezen változók együttesen sem képesek a területi vagyoni elkülönülést teljesen megmagyarázni, maradnak területi tendenciák az adatokban. Van tehát egy olyan láthatatlan komponense a vagyoni

klasztereződésnek, amelyet nem magyarázni lehet, hanem létezését tudomásul véve megpróbálni ellensúlyozni.

A kontrollálás után fennmaradó területi autokorreláció hatástávolságát is megvizsgáltuk. Ahogy az épített SAR-modellek is megerősítik, a 2012-es adatok esetén a 45 kilométeres bináris távolságmátrix adja az optimális modellt, a 2018-as adatok esetén pedig egy másodlagos szomszédokat is figyelembe vevő szomszédságmátrix. Mindkét esetben az eredeti 35 kilométeres optimális távolságmátrixnál nagyobb területeket érintő súlymátrixok voltak optimálisak a SAR modellben. Ebből az következik, hogy miután kontrollálunk releváns változókra, a fennmaradó területi autokorreláció egy általános nagyobb régió vagy terület mentén marad fenn, melyeket gazdasági vagy szegénységi zónákként definiálunk.

Ezen elemzésekkel mindhárom kutatási kérdésünkre egzakt választ tudtunk adni. Az eredmények implikációja az, hogy a vagyonos lakosságok helyi szinten egymás vagyoni szintjét képesek spillover hatások formájában feljebb húzni. Ez a húzóhatás többek között a működő vállalatok számán (melyek munkahelyeket biztosíthatnak a vizsgált területnek), a tartósan munkanélküliek arányán (akik az idő múlásával egyre nehezebben találhatnak alkalmazást) vagy az adózók arányán túl mutat. Ez azt is jelentheti, hogy a vagyonos lakosság és járások területi elkülönülése azért van egyensúlyi állapotban (2012 és 2018 hőtérképeinek, területi autokorrelációs mutatóinak és a SAR modellek területi korrelációs komponenseinek összevetése alapján), mert ezek az elkülönülési folyamatok képesek újratermelni magukat. Ez szociálpolitikai szempontból azt is magával vonja, hogy amennyiben egy kormányzat enyhíteni kívánja a vagyoni alapú területi elkülönülést a társadalomban, úgy nem elég „könnyen” megragadható mérőszámok kiegyenlítésére fókuszálnia, mint például a munkanélküliség, a gazdasági aktivitás (működő vállalatok, adózók száma) vagy demográfiai megoszlás (65, illetve 60 éven felettiek aránya).

Konklúzióképp végül még azt mondhatjuk, hogy a vagyoni elkülönülés Magyarországon 2018-ban és 2012-ben is jelentős volt, ennek mértéke enyhén nőtt ezen időintervallumban. A 2021-es, még nem nyilvánosan elérhető adatok esetén sincs ennek fényében ok mást feltételezni, jelenünk is minden bizonnyal hasonló folyamatokkal írható le.

6. Irodalomjegyzék

Anselin, L. (1995). Local indicators of spatial association—LISA. *Geographical analysis*, 27(2), 93-115.

Csité András, Németh Nándor (2007). Az életminőség területi differenciái Magyarországon: a kistérségi szintű HDI becslési lehetőségei. *Budapesti Munkagazdaságtani Füzetek*, 3.

Czirfusz Márton (2015). A közfoglalkoztatás térbeli egyenlőtlenségei. *Munkaerőpiaci tükrök* 2015, 126-138.

Duncan, O. D., Duncan, B. (1973). Lakóhelyi szegregáció és foglalkozási rétegződés. In: Szelényi Iván (szerk.): *Városszociológia*. Közgazdasági és Jogi Könyvkiadó, Budapest, 182-202.

Kertesi Gábor, Kézdi Gábor (2005). Általános iskolai szegregáció, I. rész. Okok és következmények. *Közgazdasági Szemle*. 52(4), 317-355.

LeSage, J. P. (2008). An Introduction to Spatial Econometrics. *Revue d'économie industrielle*, 123(3), 19-44.

LeSage, J., Pace, R. K. (2009). *Introduction to spatial econometrics*. Chapman and Hall/CRC.

Nagy Erika, Timár Judit, Nagy Gábor, Velkey Gábor (2015). A társadalmi-térbeli marginalizáció folyamatai a leszakadó vidéki térségekben. *Tér és Társadalom*, 29(1), 35-52.

Szakálné Kanó Izabella, Kazemi-Sánta Éva, Lengyel Imre (2018). A felsőfokú végzettségűek területi eloszlásának alakulása Magyarországon. In *Térségek növekedése és fejlődése: egészségipari és tudásalapú fejlesztési stratégiák*, 174-196. Szeged: JATEPress Kiadó.

Tobler, W. R. (1970). A computer movie simulating urban growth in the Detroit region. *Economic geography*, 46(sup1), 234-240.

Varga Attila (2002). Térökonometria. *Statisztikai Szemle*, 80(4) 354-370.

Adatok forrása:

2012-es adatok:


KSH (2012). *Területi statisztikai évkönyv, 2012*. Központi Statisztikai Hivatal, Budapest.

2018-as adatok:


KSH (2018). *Területi statisztikai évkönyv, 2018*. Központi Statisztikai Hivatal, Budapest.

7. Melléklet


7.A Az ezer lakosra jutó működő vállalatok számának hőtérképe 2018-ban (bal) és 2012-ben (jobb)




7.B A 65 éven (2018, bal), illetve 60 éven (2012, jobb) feletti lakosság arányának hőtérképe.



7.C Az ezer lakosra jutó adózók számának hőtérképe 2018-ban (bal) és 2012-ben (jobb).



7.D Állandó lakosságszám hőtérképe 2018-ban (bal) és 2012-ben (jobb).



7.E A SAR modellek hibatagjainak Moran pontdiagramjai 35 km-es távolságmátrixszal vizsgálva 2018-ban (bal) és 2012-ben (jobb).

