

DOKTORI ÉRTEKEZÉS

Sebestyén Tamás

Pécs, 2011

PÉCSI TUDOMÁNYEGYETEM
KÖZGAZDASÁGTUDOMÁNYI KAR
GAZDÁLKODÁSTANI DOKTORI ISKOLA

Sebestyén Tamás

**HÁLÓZATI STRUKTÚRÁK SZEREPE
A GAZDASÁGI TELJESÍTMÉNYBEN**

A MODELLEZÉS ÉS AZ EMPIRIKUS
VIZSGÁLAT LEHETŐSÉGEI

DOKTORI ÉRTEKEZÉS

Témavezető:
Dr. Bessenyei István

Pécs, 2011

Pécsi Tudományegyetem
Közgazdaságtudományi Kar
Gazdálkodástani Doktori Iskola
Iskolavezető:
Dr. Bélyácz Iván, egyetemi tanár

Témavezető:
Dr. Bessenyei István, egyetemi docens

Tartalomjegyzék

1. Bevezetés	1
2. Szakirodalmi alapvetés és tézisek	5
2.1. Bevezető gondolatok és definíciók	5
2.1.1. A tudás fogalmának definíciós nehézségei	6
2.1.2. A tudás közgazdasági reprezentációja	7
2.2. A tudás szerepe a közgazdasági gondolkodásban	10
2.2.1. Tudás és gazdasági növekedés a klasszikus gondolatokban	10
2.2.2. A neoklasszikus és a keynesi közgazdaságtan	12
2.2.3. A modern növekedésemélet kiindulópontja: a Solow modell	13
2.2.4. Endogén növekedésemélet	15
2.2.5. Technológiai diffúzió	18
2.2.6. Tudás-spilloverek és lokalitás	19
2.3. Hálózatok és innováció	23
2.3.1. A hálózati struktúra	24
2.3.2. Hálózati társadalom és az új gazdaság	27
2.3.3. Tudáshálózatok vizsgálata	29
2.3.3.1. Elméleti modellek	30
2.3.3.2. Empirikus vizsgálatok	33
2.4. A disszertáció tézisei és felépítése	36
2.4.1. Tézisek	36
2.4.2. A disszertáció struktúrája	39
3. Az általános egyensúly hálózati kapcsolatokkal bővített modellje	40
3.1. Hálózatok matematikai reprezentációja	41
3.2. Az alapmodell bemutatása	42
3.2.1. A gazdaság kínálati oldala	42

3.2.2. A gazdaság keresleti oldala	46
3.2.3. Általános egyensúly	48
3.3. Egy speciális eset – szimmetrikus vállalatok	50
3.4. Hálózati struktúrák értelmezése	54
3.4.1. SNA mutatók	55
3.4.2. Hálózati modellek	59
3.4.2.1. A Watts-Strogatz hálózati modell	59
3.4.2.2. A Barabási-Albert hálózati modell és kiterjesztése	62
3.5. Egyensúly a statikus hálózatokkal kibővített modellben	65
4. Modell-szimulációk és analízis	69
4.1. Paraméterek meghatározása	69
4.2. Kis világok és általános egyensúly	74
4.3. Skálafüggetlenség és általános egyensúly	81
4.4. A tudás diverzitásának szerepe	85
4.4.1. Diverzitás a Watts-Strogatz modellben	86
4.4.2. Diverzitás a módosított Barabási-Albert modellben	88
4.5. Tudás-diffúzió statikus hálózatokban	90
4.5.1. Technológiai sokkok közvetlen hatásai	90
4.5.2. Technológiai sokkok dinamikus vizsgálata	95
4.5.3. Stacionaritás és átmeneti sokkok – egy kiegészítés	101
5. Regionális feltalálói hálózatok és termelékenység – empirikus elemzés	105
5.1. Az adatbázis leírása	106
5.1.1. Eurostat adatok	106
5.1.2. Hálózati adatbázis	107
5.2. Empirikus modellek és eredmények	111
5.2.1. A regionális TFP értékek becslése	112
5.2.2. A tudás-aggregátor becslése	120
5.2.2.1. Tudásállomány szabadalmakon keresztül	121
5.2.2.2. Hálózatok és külső tudás	122
5.2.2.3. Panel regressziók a tudás aggregátor becslésére	125
5.2.2.4. Korrigált empirikus változók	127
5.2.2.5. Negatív koefficiensek a szimulációs modellben	133

6. Kísérlet a hálózati struktúra és a gazdasági teljesítmény közötti kapcsolat empirikus elemzésére	140
6.1. A felhasznált adatok	140
6.1.1. Gazdasági teljesítmény	140
6.1.2. Hálózati struktúra	141
6.2. Szabadalmi hálózati struktúrák leíró elemzése	145
6.2.1. Alapvető hálózati mutatók alakulása	145
6.2.2. Kis világok	147
6.2.3. Skálafüggetlenség	150
6.2.4. A hazai regionális szabadalmi együttműködési hálózat fejlődése	151
6.3. A gazdasági teljesítmény és a hálózati struktúra közötti kapcsolat elemzése	155
7. Fejlesztéspolitikai szimulációk kalibrált modell segítségével	160
7.1. A modell kalibrálása	160
7.1.1. Átvett és becsült paraméterek	161
7.1.2. A spillover paraméter kalibrálása	162
7.1.3. A kalibrálás tapasztalati bázisa	165
7.1.4. A kalibrálás menete	165
7.2. Szimulációk a kalibrált modell segítségével	168
7.2.1. Centrum és periféria a gazdaságban és a hálózatokban	168
7.2.2. Technológiai sokkok dinamikus hatása	169
7.2.3. A technológiai sokk hatása aggregált szinten	172
7.2.4. A hálózati struktúra szerepe	174
8. Összegzés	176
Irodalomjegyzék	181
Függelék	191
Ábrák jegyzéke	218
Táblázatok jegyzéke	221

Köszönetnyilvánítások

A disszertáció elkészítéséhez számos irányból fontos segítséget kaptam. Mindenekelőtt konzulensem, Bessenyei István szakmai és emberi támogatását kell megköszönnöm, aki munkámat attól kezdve támogatta és segítette, hogy a közgazdasági kutatás iránt még egyetemista koromban érdeklődni kezdtem. Köszönet illeti Varga Attilát is, aki tanszéki kollégámként és intézetigazgatóként is nélkülözhetetlen segítséget nyújtott munkám során. Az ő iránymutatása alapján sikerült eljutnom olyan doktoranduszoknak szánt programokra, amelyek gondolkodásomat nagy mértékben orientálták és a disszertáció témája iránti érdeklődésemet elmélyítették. Szintén hasznosnak bizonyult az az anyagi támogatás is, amit a DIME hálózat nyújtott és lehetővé tette külföldi tanulmányutak és konferenciák látogatását. Ugyanebből a szempontból nyújtott nagy segítséget a Pécsi Tudományegyetem Közgazdaságtudományi Karának támogatása, amely szintén konferencia-részvételeket és tanulmányutakat tett lehetővé. Külön ki kell emelnem a Kar Gazdálkodástani Doktori Iskolájának anyagi támogatását, többek között egy hosszabb milánói tanulmányút finanszírozásában, amely során értékes szakmai kapcsolatokkal és tudással gazdagodtam. A Doktori Iskola vezetőjének, Bélyácz Iván professzornak biztató támogatása is sokat jelentett. Két kollégám, Parag Andera és Kruzslíc Ferenc segítése és együttműködése is fontos pontokon járult hozzá a disszertáció elkészítéséhez: a velük közösen készült kutatások a dolgozat empirikus részének alapvető bázisát adják. Andreával, mint tanszéki szobatársammal folytatott eszmecserek is nagy mértékben hozzájárultak a dolgozat formálódásához. Hasonlóan fontos annak a sok észrevételnek, megjegyzésnek a szerepe is, amelyeket különböző konferenciákon, intézeti szemináriumokon kaptam a kutatási munkát bemutató előadások kapcsán. Nagyon fontosnak érzem továbbá a Kar és szűkebb tanszékelem inspiráló, támogató közegének szerepét, amely nélkül ez a munka talán nem ilyen formában, de mindenképpen lassabban készült volna el.

Köszönettel tartozom családomnak is: szüleimnek, akik szerető támogatása folyamatos belső biztatást adott ebben a munkában, testvéreimnek támogatásukért valamint az egyes technikai problémák megoldásában nyújtott nélkülözhetetlen segítségükért. Legfőképpen azonban a két Melindának tartozom hálával, akik nélkül ez a munka a legvégső célját veszítette volna el.

1. fejezet

Bevezetés

Ha áttekintjük az elmúlt néhány évszázad gazdaságtörténetét a nyugati világban, azt látjuk, hogy ez alatt az időszak alatt, a rövidebb távú kilengésektől eltekintve, egy igen dinamikus növekedési trend tapasztalható a gazdasági teljesítményt tekintve. A közgazdaságtan egyik alapvető kérdése tulajdonképpen már a klasszikus közgazdászok generációja óta, hogy mi tekinthető e növekedés fő forrásának.

A kérdés megválaszolása érdekében tett tudományos erőfeszítések egy nagyon fontos, intuitív alapokon is könnyen értelmezhető és belátható következtetésre vezetnek: a növekedés legvégső forrása a gazdaságban felhalmozódó tudás. Ez a kijelentés bizonyos szempontból ingoványos területre vezeti a kutatót: a tudás fogalma, jelensége oly kevésbé megfogható, hogy a relatíve egzaktan nevezhető közgazdaságtan fogalmi rendszerébe történő beépítése szükségszerű kompromisszumokkal jár. Ugyanakkor az is kiderül, hogy a tudás felhalmozásának rendkívül széles körű aspektusain belül található egy-két olyan dimenzió, amely a közgazdasági gondolkodás hagyományos fogalmi rendszerébe könnyűszerrel beépíthető.

A hosszú távú növekedés egyrészt a termeléshez szükséges erőforrások bővüléséből, másrészt pedig ezen erőforrások felhasználásának hatékonyabbá válásából fakad. Ez utóbbit a közgazdasági és elsősorban a gazdasági növekedéssel foglalkozó szakirodalom átfogóan technológiai haladásnak vagy technológiai fejlődésnek nevezi. Ez a kifejezés arra utal, hogy az anyagi értelemben vett gazdasági növekedés elsősorban a termelési struktúrákban bekövetkező fejlődési tendenciák által meghatározott, vagyis a háttérben mindig a termelési technológia és ennek pozitív irányú változásai állnak. A technológia változásai a közgazdaságtan egyik alapvető fogalma, a termelési függvény dimenziójában már értelmezhetőek, így ezek a változások és következményeik a hagyományos fogalmi keretek között tárgyalhatóak.

Fontos azonban az a felismerés is, hogy a technológia változása az innovációból, új ötletek megjelenéséből ered. Valamennyi technológiai és egyéb gazdasági innováció alapja az, hogy valaki új ötletekkel áll elő a termelés szervezését illetően. Ez az ötlet rendkívül széles körből származhat, sőt, a lényegesebb innovációk valójában több területen felbukkanó újításokat ötvöznek a tudományos alap kutatások eredményeitől kezdve a termelésszervezés

praktikus meglátásaiig. Ezek az ötletek, innovációk ugyanakkor új tudást is jelentenek: a technológia hatékonyabbá tétele éppen azért lehetséges, mert valamilyen új információ, új tudás jelenik meg a gazdaságban, megnyitva az utat a termelékenység növekedése előtt.

Ahogy a technológia fejlődése visszavezethető a gazdaság számára elérhető, rendelkezésre álló tudás felhalmozásával, úgy a tőkeállomány változásai is érdekes kérdéseket vetnek fel ebből a szempontból. A szó hétköznapi értelmében a technológia fogalmába sokszor beleértjük az alkalmazott tőke mennyiségét, minőségét is. Ha a gazdasági tevékenység fejlődését historikus perspektívából szemléljük, akkor könnyű felismerni, hogy a fogalmaknak ez az összemosódása logikus összefüggésen alapszik: a tőkeeszközök használatba vétele, majd folyamatos fejlődése éppen abban a folyamatban játszott/játszik fontos szerepet, amely során az emberi munka, mint a termelési rendszereket legvégső soron üzemeltető és irányító termelési tényező egyre hatékonyabbá, termelékenyebbé vált. Ugyanakkor a gazdaságban megjelenő tőkeeszközök is a gazdaság szereplőinek a természet és a termelési rendszerek működéséről felhalmozott tudását testesítik meg, kezdve a legegyszerűbb kőbaltától az atomerőművekig. Mindezek alapján azt a megállapítást tehetjük, hogy a hosszú távú gazdasági növekedés háttérében a tudás felhalmozása áll, csupán e tudás megjelenési formája más és más. Megjelenhet a felhalmozott és a termelésben alkalmazott tőkeeszközökben, megjelenhet a gazdaság szereplőinek egyéni (vagy szervezeti) tudásában (emberi, társadalmi tőkében) és megjelenhet azokban a termelési rendszerekben, eljárásokban, amelyek az előbbi két termelési tényezőt kombinálva a termelő tevékenységet végzik. A hosszú távú perspektíva tehát azt a következtetést biztosítja, hogy ebből a nézőpontból a növekedés és a tudás felhalmozásának fogalmi szorosán összekapcsolhatóak.

A tudás kiemelkedő szerepének felismerése felveti a tudás kialakulásának, az innovációnak a kérdéseit. Az utóbbi néhány évtizedben a közgazdasági irodalom nagy érdeklődéssel fordult az innováció kérdései fel: melyek azok a faktorok, amelyek az innováció kialakulásához vezetnek? Milyen tényezők járulnak hozzá ahhoz, hogy egy ország vagy térség folyamatosan magas szintű innovációs aktivitást mutat, míg más térségek kevésbé sikeresek ezen a téren. Milyen feladata, szerepe lehet az államnak ezen a téren?

Az új ötletek kialakulása, a tudás megjelenése mellett lényeges kérdés az is, hogy miképpen válik a gazdaság elszigetelt pontjain (vállalatoknál, kutatóintézetekben, egyéni feltalálók-nál) kialakuló új tudás a gazdasági növekedés motorjává? Ebből a szempontból rögtön két kérdés is felmerül. Egyfelől a megjelenő új ötletek miként válhatnak praktikus termelési eljárásokká, másfelől pedig az egyedileg implementált újítások miként válnak a gazdaság egésze számára hozzáférhetővé, hogyan terjednek el az alkalmazók között és hogyan alakítják ki végül azokat az externális hatásokat, amelyek a gazdaság makroszinten is érzékelhető növekedéséhez vezetnek. Ez utóbbi felvetés a tudás terjedésének, diffúziójának kérdéséhez vezetnek, amely logikus folyamánként adódik a hálózati kapcsolatok és struktúrák szerepének vizsgálata, amely a disszertáció központi eleme.

A hálózatok kutatása azonban a matematika és a fizika felől a szociológián át ért el az innovációval foglalkozó szakirodalomhoz. A matematika gráfelmélet nevű területe írja le azt

az absztrakciós sémát, amely a jelenségek közötti kapcsolódások vizsgálatát teszi lehetővé. A gráfelmélet első megjelenése Euler híres königsbergi problémájáig nyúlik vissza, aki felismerte, hogy az útvonaltervezés egy absztrakt struktúra elemzésével is megoldható, ahol csomópontok vagy csúcsok helyszíneket, a csomópontokat összekötő kapcsolatok vagy élek pedig a helyszínek közötti utakat jelölnék.

Nyilvánvaló azonban, hogy a csúcsokból és élekből álló struktúra (a gráf) nem csupán térképek reprezentációjára alkalmas: absztrakciós szintjénél fogva ezzel a rendszerrel rendkívül sok jelenség leírható, kezdve a társadalmi kapcsolatoktól a geometriai alakzatokon és biológiai rendszereken át komplex termelési rendszerekig. A hálózatokkal kapcsolatos legfrissebb kutatások arra mutatnak, hogy amennyiben ezeknek az egymástól alapvetően eltérő rendszereknek hálózati interpretációt adunk és az így kapott kapcsolati háló struktúráját vizsgáljuk, kiderül, hogy e struktúrák között alapvető hasonlóságok fedezhetőek fel. Az is felfedezhető, hogy a struktúra és a struktúrára épülő rendszer teljesítménye lényeges pontokon összefügg egymással.

Ezen a ponton a gondolatmenet visszatér az innováció és diffúzió kérdésköréhez. A gazdaság szereplőit felfoghatjuk egy hálózat csomópontjainak és az őket összekötő formális vagy informális, piaci vagy nem piaci kapcsolatokat pedig a hálózat éleinek. Az új tudás diffúzióját és ezáltal a gazdaság teljesítményét, a gazdasági növekedést így ezek a hálózati kapcsolatok és amennyiben a hálózatelmélet analógiáját használjuk, ezek specifikus struktúrája alapvetően befolyásolja. Bár látszólag elsőre fel nyilvánvaló kapcsolat az új tudás létrejötte, azaz az innováció, és a hálózati struktúra között, az is kiderül, hogy ezek a struktúrák nem csak a már exogén módon kialakult tudás diffúziójának jellemzőit befolyásolják, hanem hozzájárulhatnak az innovativitás kialakulásához és fennmaradásához is.

A disszertáció ezen a ponton kapcsolódik az imént vázlatosan tárgyalt szakirodalmi áramlatokba és gondolatmenetbe. Alapvetően azt a kérdést teszi fel, hogy milyen szerepe van a hálózati struktúráknak a gazdasági teljesítmény alakulásában, így tulajdonképpen az előbbi gondolatmenet zárása irányába tesz egy lépést. Amennyiben a tudás felhalmozása lényeges eleme a gazdaság hosszú távú növekedésének, és amennyiben a hálózati struktúrák szerepe lényeges a hálózatra épülő rendszer teljesítményének alakulásában, akkor a tudás terjedését és kialakulását befolyásoló *tudáshálózatok* és azok struktúrája milyen módon kapcsolódik a gazdasági tevékenység változásaihoz és ezáltal a gazdasági növekedés megfigyelt jelenségeihez?

Ebben a kontextusban a disszertáció kettős célt követ. Egyfelől a hálózatelmélet és a hálózati struktúrák vizsgálata valamint a közgazdasági elmélet közötti kapcsolat szorosabbra fűzése áll a fókuszban, ami azt jelenti, hogy az előbbi terület módszertani apparátusát alkalmazza a közgazdaságtan általánosan használt modellezési keretein belül. Ez ugyan csak egy, de lényeges lépésnek tekinthető az előző bekezdésben vázolt gondolati kör bezárása tekintetében. A cél ebből a szempontból egy olyan elméleti keret megteremtése, amely alkalmas lehet a hálózati struktúrák és a gazdasági dinamika közötti kölcsönhatások elemzésére.

A dolgozat másik célja az empirikus hálózatkutatás gazdasági és innovációs hálózatokkal kapcsolatos területének bevonása az első cél érdekében tett lépések értékelésébe. Így részben már alkalmazott módszerekre építve, részben pedig új perspektívákat használva a disszertáció elméleti részében foglalt megállapítások és elvek empirikus igazolását keressük, részben pedig az így felhalmozott információkkal is gazdagítható a tudáshálózatokkal kapcsolatos empirikus ismerethalmaz.

2. fejezet

Szakirodalmi alapvetés és tézisek

Ebben a fejezetben bemutatom azt az alapvető szakirodalmat, amely a dolgozat megírásához inspirációt és bázist nyújtott. Ezt követően a szakirodalomra építve felállítom azokat a hipotéziseket, amelyek a disszertáció során tárgyalásra kerülnek. Tekintve azonban a témához kapcsolódó szakirodalom óriási terjedelmét, nem vállalkozhatok a korpusz részletes és teljes áttekintésére. Éppen ezért az alábbi áttekintés inkább egy gondolati vezérfonalnak tekinthető, amely kiemeli azokat a fontosabb elméleti csomópontokat, amelyek egy logikai láncra fűzve a disszertációban tárgyalt kérdések felvetéséhez vezetnek. Ez a gondolati vonal egyúttal reprezentálja azt az ívet is, amit érdeklődésem az elmúlt években végigjárt, és a disszertációban szereplő kérdések felvetéséhez vezetett. Természetesen a hálózatok és a tudás-áramlás kapcsán igyekszem releváns áttekintést adni, és kiemelni azokat a fontos pontokat, amelyeken a disszertáció beilleszthető a témával foglalkozó kutatási irányvonalakba, és amelyek egyben a dolgozat logikai alapját is képezik. Mindezeknél fogva az alábbi áttekintés célja kettősnek tekinthető: egyrészt bemutatja azt a szakirodalmi háttérrel, amelyre a dolgozat szűken vett témakörei épülnek, másrészt viszont dokumentálja egyfajta személyes kutatási érdeklődés kialakulását is, így szélesebb szakirodalmi kontextust is ad az itt felvetett témáknak.

2.1. Bevezető gondolatok és definíciók

A disszertáció egyik központi témája a tudás és annak gazdasági szerepe. E meglehetősen általános és nehezen megragadható fogalom az utóbbi egy-két évtizedben vált a közgazdasági gondolkodás fontos részévé, azonban mind a mai napig problematikusnak tekinthető a fogalom definíciója és interpretációja. Éppen ezért, mielőtt az irodalmi áttekintés érdemi részére áttérnék, először néhány gondolat erejéig kitérek a tudással kapcsolatos definíciós kérdésekre. Először – szükségszerűen szelektív – definíciós háttérrel adok a tudás fogalmának, amelyet az ahhoz kapcsolódó, leglényegesebb kategóriák ismertetésével egészítek ki. Ezt követően a tudás fogalmának közgazdasági interpretációjára térek ki röviden.

2.1.1. A tudás fogalmának definíciós nehézségei

A tudás definíciója kapcsán természetesen alapvető filozófiai kérdések is felvetődnek, e helyen azonban mindössze néhány alapvető sarokpont rögzítése lehet a cél. A tudás rendkívül sokféle meghatározása közül a legáltalánosabban elterjedt változatot alkalmazom, részben praktikus okokból, részben pedig azért, mert ennek egyfajta logikai folyománya egybevág a disszertáció apropójával, nevezetesen a tudáshálózatok jelenségével és szerepével.

Az általános definíció a tudást egyfajta hierarchikus struktúraként fogja fel (pl. De Carvalho és szerzőtársai, 2006). A hierarchia alján az elemi tények, adatok találhatóak. Ezek olyan ismeret-egységek, amelyek numerikus adatok, vagy akár (kézenfekvő, de nem teljesen pontos példával élve) egyszerű kijelentő mondatok formájában jelennek meg. A hierarchia második szintjén az információ újdonságot jelentő tényként kerül definiálásra. A tudás a hierarchia harmadik, legfelső szintjén jelenik meg és információk strukturált halmazaként értelmezhető. Ebből a szempontból a tudás tekinthető adatok és információk speciális hálózatának, ahol az alacsonyabb szintű összetevők kapcsolódása (végső soron a hálózat struktúrája) határozza meg a magasabb szintű jelenséget, jelen esetben a tudást.¹

Az előbbi definíció fontos következményeket implikál. Az, hogy a tudás információk strukturált halmaza, azt is jelenti, hogy maga nem független attól a módtól, ahogyan ez a struktúra kialakul, sem attól, hogy milyen információk alapján alakul ki. Ez egyben azt is felveti, hogy a hierarchikus megközelítés ugyan szemléletes, de a hierarchia nem jelent egyértelmű megfeleltetést tények, információk és tudás között. Éppen ellenkezőleg: azonos tények és információk alapján egyénenként különböző tudás jöhet létre, sőt, ugyanaz a tudás eltérő tények és információk alapján is kialakulhat. Ez azt jelenti, hogy a jelenség nagy mértékben kontextus-függő (Nooteboom, 2004). Nyilván ez a komplex viszony a tudás alkotóelemei között nagyban hozzájárul a tudás definícióval kapcsolatos bizonytalansághoz.

Fontos pont a tudás két alapvető típusának, a kodifikált és a tacit (vagy más interpretációk szerint explicit és implicit) tudásnak a megkülönböztetése, amely eredetileg Polányitól származik (Polányi, 1967). Kodifikált tudásnak nevezzük az olyan elemeket, amelyek valamilyen módon leírhatók, formalizálhatók. A tacit tudás ezzel szemben az egyéneknél rejlik, nem formalizálható. Némileg homályos a fenti hierarchikus tudás-definíciónak és a tacit/kodifikált dimenzióknak az elhatárolása. De Carvalho és szerzőtársai (2006) a fenti hierarchia szerinti tényeket és információt tekintik kodifikálhatónak, míg a tudást tacitnak tartják. Ezzel szemben Nooteboom (2004) definíciójában a kontextusban, információk struktúrájában megjelenő tudás lehet tacit is és kodifikált is, mint ahogy Polányi eredeti elképzelése szerint is minden tudás-elem tartalmaz tacit és kodifikált részt is. Mindezek ellenére a tudás-áramlással és innovációval foglalkozó mai irodalom tipikusan szétválasztja (de legalábbis szétválaszthatónak tartja) a tacit és kodifikált tudást (pl. Nelson és Winter, 1982).

¹Itt egy intuitív utalást tehetünk az emberi agy működésére, ahol idegsejtek milliárdjainak hálózata biztosítja azt a jelenséget, amelyet tudásnak nevezünk. Ebből a szempontból a tudással kapcsolatos kérdések hálózati perspektívában történő tárgyalása akár az individuálisnál magasabb szinteken is relevánsnak tekinthető.

Az előbbiekben a tudást egyéni szinten definiáltuk. A kapcsolódó akár szociológiai, akár gazdasági szakirodalom definíciói azonban nem állnak meg az egyéni értelmezés szintjén. A szervezeti struktúrával vagy a tudásmenedzsmenttel kapcsolatos irodalom kiemeli az egyéni és a szervezeti tudás közötti különbséget. A szervezeti (vagy csoport-) tudás az egyéni tudás mellett fontos addicionális dimenziót tartalmaz. Legegyszerűbb definíciója szerint a szervezeti tudás a szervezet tagjai által közösen, együttesen elfogadott tudás-elemek alapján létrehozott ismeret-halmazként értelmezhető (Nonaka, 1994). A szervezeti tudást eszerint az különbözteti meg az egyéni tudástól, hogy az előbbit az utóbbiak közötti kapcsolatok, interakciók határozzák meg, így a szervezeti tudás alkalmazása sem lehetséges egyénileg. Ez a szuper-individuális dimenzió természetesen tovább bővíthető szervezeten felüli, például regionális vagy országos értelmezésekkel.² Ezek a szervezeten felüli, de térben korlátos tudás-dimenziók explicit módon is megjelennek az innovációs rendszerek vagy a helyi innovációs milió irodalmában, amely szerint a helyi kultúrában, szokásokban, közösen osztott értékekben, a helyi szervezetek kapcsolataiban (tehát egyfajta speciális tudásban, társadalmi tőkében) rejlik az az erő, amely az innovációs potenciál kialakulásáért és fennmaradásáért nagy részben felelős, eképp hozzájárulva az adott területi egység gazdasági prosperitásához.³

Egy további fontos jellemzője a fogalomnak – immár konkrét közgazdasági vonatkozásokkal –, hogy gazdasági értelemben a tudás egy speciális tőkefajtának tekinthető. Ez a szemléletmód elsősorban Becker és Schultz munkái révén vált népszerűvé (Becker, 1964; Schultz, 1983), és arra a megfigyelésre épül, hogy a tudás a fizikai tőkéhez hasonló tulajdonságokkal is rendelkezik: felhalmozható és amortizálódik. Ez azt is jelenti, hogy a felhalmozás a „hagyományos” értelemben vett beruházás révén lehetséges: jelenbeli erőforrások lekötését igényli, amely befektetés majd későbbi időpontokban térül meg. Ezt a fajta beruházást általában tanulásnak nevezzük. Ezen az irányvonalon indulva juthatunk el a tanuló régiók (learning regions) koncepciójához, amely a tudás-felhalmozás (kutatás-fejlesztés, innováció), vagy az alternatív interpretáció szerint tanulás jelentőségét hangsúlyozza a regionális gazdasági fejlődés kapcsán (lásd pl. Florida, 1995).

2.1.2. A tudás közgazdasági reprezentációja

Minthogy a disszertáció témája közgazdasági jellegű, így fontos, hogy a tudás közgazdasági interpretációját is megvizsgáljuk. Az előző szakaszban kitértem a tudás tőkeként történő értelmezésére, ami egyben azt is jelenti, hogy a tudás fogalma speciális közgazdasági tartalommal bír: vagyis a tudás gazdaságilag hasznos jószágként definiálható.

A gazdasági javak kategorizálása során a tudás elhelyezése nem triviális. A magánjavak és közjavak klasszikus csoportosítása szerint a tudás jellemzően nem magánjószág, hiszen

²Ismét egy intuitív kiegészítésként, akár C.G. Jung kollketív tudattalanjához is eljuthatunk – természetesen szigorúan heurisztikus gondolatmenet alapján, egyfajta érdekes felvetés formájában (Jung, 1993).

³Az innovációs rendszerekről lásd például Cooke, 2005. Az innovációs milió irodalmáról áttekintést ad: Guesnier, 1998.

esetében nem érvényesül a fogyasztásban történő rivalizálás feltétele, ugyanakkor nem is nevezhető tiszta közjóságnak, mivel a fogyasztásból történő kizárásnak, legalábbis általánosságban, vannak módszerei. Általánosan elfogadott a tudást kvázi-közjóságnak, vagy egyes esetekben közjóságnak tekinteni. Természetesen az aktuális értelmezés nagy mértékben függ az adott kontextustól. Egy egyén által felhalmozott tudás esetén értelmezhető a fogyasztásból történő kizárás, míg például a hosszabb időn keresztül a gazdaság egészében felhalmozódó technológiai tudás esetén ez a kizárás már kevésbé triviális.

A fogyasztásból történő kizárás problémaköréhez tartozik a tudáshoz kapcsolódó externáliák kérdése. Amennyiben a felhalmozott tudásnak csak kis része is olyan, hogy a tudás „birtokosa” nem tudja önkényesen kizárni annak fogyasztásából a gazdaság többi szereplőjét, úgy a tudásba történő beruházás externális hatásokat generál. A tudást felhalmozó egyénen vagy más gazdasági szereplőn kívül harmadik személyek úgy juthatnak hozzá a tudás hozadékához, hogy nem járultak hozzá a felhalmozáshoz. Általánosan elfogadott vélekedés, hogy a tudás felhalmozásával kapcsolatos ilyen extern hatások tipikusan pozitívak: a technológiai fejlődés pozitív hatásaitól kezdve a szélesebb tudású népesség által generált pozitív társadalmi hatásokig számos példa mutatja, hogy a tudás felhalmozása jellemzően kedvező extern hatásokkal jár együtt (lásd pl.: Schultz, 1983).

A tudás e pozitív externális hatásai explicit módon Alfred Marshall (1890) művében jelennek meg először, aki a lokalizációs externáliák között említi a tudás lokális terjedésének szerepét. Implicit módon azonban a tudás felhalmozásának pozitív hatásai már Smith gondolataiban felbukkannak. A Marshall által rögzített alapokat mintegy újból felfedezve indult el később a tudás-transzferek, vagy angol eredetű elnevezéssel a tudás-spilloverek irodalma, amelyre a továbbiakban majd részletesen is kitérünk.

Egy további fontos kérdés a tudás reprezentációja a közgazdasági modellekben. Ez a kérdéskör azért is fontos, mivel a disszertáció részben a modellezés módszertanára épít. Ebből a szempontból talán Arrow (1994) megjegyzése ragadja meg a legjobban a lényegét. Szerinte ugyan a tudás nagyon sok dolognak a tudását jelenti és rendkívül különböző dimenziókban jelentkezhethet, a neoklasszikus vagy akár evolúciós közgazdasági modellekben a tudás nem más, mint egy szám: a tényezőtermelékenység (factor productivity), vagy másképpen teljes tényezőtermelékenység.⁴

Technikai értelemben véve a TFP a termelési függvény együtthatója, így minden olyan, a kibocsátás nagyságára ható faktor hatását tükrözi, amelyet nem sorolunk a termeléstényezők közé. Amennyiben egy „klasszikus” termelési függvényt tekintünk, tőkével és munkával, mint termelési tényezőkkel, akkor a TFP minden olyan hatást tartalmaz, amely a kibocsátást befolyásolja a munkaerő és a tőke állományán kívül. Így természetesen ide tartozhat a munkaerő képzettségi szintje (tudása), amennyiben ezt nem integráljuk a munkaerő tényező mérésébe. Magában foglalja a technológia általános színvonalát, de akár egy ország kulturális hagyományait, intézményi feltételrendszerét is tükrözheti, amennyi-

⁴A továbbiakban a teljes tényezőtermelékenység kifejezés rövidítésére szokásos módon az angol TFP (Total Factor Productivity) betűszót használom.

ben ezek hatással vannak a kibocsátásra. Ebből a szempontból tehát a TFP egy nagyon szélesen értelmezett tudás-definíciót takar. Megjegyzendő ugyanakkor az is, hogy a technológiai tudás egy része a fizikai tőkeállományba ágyazódva jelenik meg a gazdaságban. A tőkeállomány piaci értéken történő számítása így e tudás-dimenziót – legalábbis részben – tartalmazza, ebből következően pedig a TFP ebből a szempontból már nem feltétlenül tekinthető az összes felhalmozott tudás mércéjének. Az utóbbi időben azonban egyre több olyan kísérletet látunk, ahol egy ország vagy régió tőkeállományának becslése során a fizikai tőke mellett az adott vizsgálati egység intellektuális vagy tudás-tőkéjét is megpróbálják számszerűsíteni, így a tudásállomány a tőkeállomány értékének részévé válik (lásd pl. Derbyshire és szerzőtársai, 2010).⁵

Látható tehát, hogy a tudás és a tőke fogalmi nem választhatóak el könnyen egymástól: bizonyos értelemben maga a fizikai tőke is felhalmozott tudást testesít meg. Hasonló nehézségek adódnak, amikor a technológia és a tudás közötti viszonyt próbáljuk meg értelmezni. Első közelítésben a tudás tágabb kategóriának tűnik, mint a technológia. Ugyanakkor a közgazdasági és elsősorban a növekedéssel és innovációval foglalkozó szakirodalomban e két fogalom összemosódik. Ez az összemosódás tulajdonképpen szorosan összefügg az eddig tárgyaltakkal. A termelési függvény termelési tényezőkön kívüli paramétereit szokás tipikusan technológiaként definiálni (szemben a technikával, amely a termelési függvény változatlan paramétere mellett különböző tényezőkombinációk mellett termelési módokat jelöl). Ilyen módon a TFP a termelési függvény paramétereként a technológiát reprezentálja. A gazdasági növekedéssel foglalkozó korai irodalom tipikusan úgy is tekintett a technológiai változásra, mint a TFP paraméter változására (tipikusan növekedésére). Ez a változás tulajdonképpen igen kézenfekvő megoldást jelent: a TFP növekedése formailag azt jelenti, hogy a gazdaság a termelési tényezők változatlan mennyiségét felhasználva magasabb output elérésére képes, vagyis a termelés hatékonyabbá válik. Természetesen a formálisan kielégítő definíció mögött továbbra is ott rejtőzik az a jelenség, hogy a hatékonyság növekedése az esetek döntő részében új felhalmozott ismeretek, innovációk eredményeként jelenik meg, így a TFP növekedése a tudás felhalmozásának következménye.

A fenti rövid kitérőből tehát az látszik, hogy a vizsgált fogalmak elhatárolása nem triviális és talán az elhatárolás nem is feltétlenül szükséges, amennyiben a vizsgált jelenségek a makroszintű növekedést érintik. Ezen a szinten a technológia és a tudás (de akár a technika is) egymást helyettesítő, egymásnak kölcsönösen megfeleltethető fogalmakként interpretálhatók. Vegyük példának Stoneman (2002) definícióját, aki szerint közgazdasági szempontból technológiának nevezzük a termékeket és szolgáltatásokat valamint azokat az eljárásokat, amelyekkel ezeket a termékeket és szolgáltatásokat előállítják. Maguk a termékek és szolgáltatások azonban felhalmozott ismereteket ágyaznak magukba, nem beszélve az előállításuk során alkalmazott eljárásokról: a termékek és eljárások, bármennyire is technikai kategóriának tekinthetőek sokszor, tulajdonképpen a felhalmozott tudás kodifikált vagy tacit megnyilvánulási formájaként jelennek meg. Így tehát eljutunk Simon (1973) legátfogóbb

⁵Módszertani szempontból ez azt jelenti, hogy a TFP érték, mint maradék-tag, egyre inkább fehér zajjá válik az ökonometriai elemzésekben.

technológia-definíciójához: a technológia legtisztább formájában tulajdonképpen tudás – tudás, amellyel céljainkat elérhetjük és problémáinkat megoldhatjuk.

Mindezen megfontolások alapján a disszertációban a tudás és a technológia fogalmakat egymással szinonimként kezelem, természetesen figyelemben tartva a köztük megjelenő esetleges interpretációs különbségeket.

2.2. A tudás szerepe a közgazdasági gondolkodásban

Bármely tudományos munka esetén felmerül az a kérdés, hogy az adott témát miképpen lehet visszavezetni az aktuális tudományterület kezdeteihez, a téma hogyan jelenik meg az elsőként megfogalmazott kérdésekben, vagy a tudományterület első művelőinek gondolataiban. Jelen dolgozat esetében meglehetősen könnyű megtalálni a kapcsolatot a közgazdaságtan első munkáival, ám ez nem a téma speciális jellegéből vagy újszerűségéből ered, hanem logikus következménye annak a fejlődési útvonalnak, amit a közgazdasági irodalom bizonyos területei bejártak.

A most következő összefoglalóval nem célokom (és nem is lehet célokom) az elmúlt hosszú időszak közgazdasági irodalmának érdemi áttekintése. A cél sokkal inkább az, hogy a disszertáció témájának relevanciáját egyfajta történeti áttekintésen keresztül érzékeltesse, egyúttal bemutassa azt a gondolati ívet, melyen keresztül a disszertáció témája fokozatosan formát öltött és véglegesült.

2.2.1. Tudás és gazdasági növekedés a klasszikus gondolatokban

Ahogy már kiemeltük, mindig impresszív, ha egy tanulmány tudományterülete gyökereiig képes visszanyúlni önmaga identifikációja során. Jelen esetben ez azt jelenti, hogy a tanulmány kérdésfelvetésének gyökereit Adam Smith munkájában kell, hogy megkeressük. A Nemzetek gazdagsága (Smith, 1959) a piaci koordináció hatékonyságának felismerése mellett nagy hangsúlyt fektet a munkamegosztásból fakadó előnyök elemzésére is. A korát megelőzően meghatározónak számító fiziokrata gazdaság-felfogással szemben, amely a földet állította az értékelmélet középpontjába, Smith már a munka és a munkamegosztás szerepét hangsúlyozza. A smithi gondolat egy körkörös, önmagába visszatérő, ha úgy tetszik „öngerjesztő” folyamatot vázol fel, amelynek lényege, hogy a specializált munkafolyamatok hatékonyabb termelést tesznek lehetővé, ugyanakkor a specializációt éppen az ösztönzi, hogy az egyes munka-folyamatokat az azt leghatékonyabban elvégezni képes személyek vagy egységek hajtják végre. A gondolat itt természetesen tartalmaz egy tyúk vagy tojás jellegű dilemmát, mondanivalóját, és a számunkra fontos gondolti tartalmat tekintve azonban ez elhanyagolható. A számunkra fontos aspektus értelemszerűen a tudás szerepe a munkamegosztási folyamatban: a termelési folyamat hatékonyabbá válása mindenképpen valamilyen új tudás, ismeret felhalmozását igényli. Ennek alapja lehet valamilyen született tehetség vagy készség az egyének esetében vagy természeti, földrajzi tényezők az

országok, régiók esetében, azonban legtöbbször a hatékonyság növelésének eszköze az új ismeretek, tudás felhalmozása és beépítése a termelési folyamatokba. Ugyanakkor a specializáció egyben katalizálja is a tanulási folyamatot, hiszen a specializált munkavégzés a figyelem fókuszálásával arra ad lehetőséget, hogy az adott, specializált területen a munkát végző szereplő fokozatos tapasztalatokat halmoz fel, amelyek idővel, összeadódva új ismeretként, specializált tudásként jelennek meg és végül gyorsabb, egyszerűbb, hatékonyabb munkavégzésben öltenek testet.

A smithi gondolat tehát egyértelműen tartalmazza a tudásnak, mint alapvető gazdasági tényezőnek a szerepét. A Nemzetek gazdagsága másik fő motívuma, a „láthatatlan kéz” éppen azért válik fontossá, mert a specializált munkavégzés szükségessé teszi a termelő tevékenységek koordinációját. A tudás szerepének megjelenése, a közgazdasági elmélet későbbi fejlődését, mint viszonyítási alapot tekintve, logikusnak is tűnik. Smith kérdésfelvetése, akárcsak a klasszikus közgazdászoké általában, a gazdaság hosszabb távú folyamatait helyezi a középpontba: melyek egy nemzet gazdagságának forrásai, melyek azok a tényezők, amelyek a nemzet anyagi gyarapodását, mai kifejezéssel élve a gazdasági növekedést elősegítik? A modern növekedésemélet első kezdeményezései végső soron éppen ugyanarra a következtetésre jutnak, mint Smith kétszáz évvel korábban, nevezetesen, hogy a tudás felhalmozása elsődleges fontosságú a gazdaság és a jólét növekedése szempontjából.

A smithi gondolatokra alapozva, David Ricardo komparatív előnyökre építő érvelése a szabadkereskedelem mellett, szintén a munkamegosztásból fakadó, kölcsönös előnyöket emeli ki (Ricardo, 1991). Érvelésének központi eleme az, hogy a munkamegosztásból nem csupán a legkedvezőbb feltételekkel rendelkező, leghatékonyabb szereplők juthatnak előnyökhöz, hanem minden résztvevő fél javíthat helyzetén. Vagyis a specializáció során az a fél is jobb helyzetbe kerülhet, aki az adott munkafolyamat bármely fázisát tekintve kisebb felhalmozott tudással rendelkezik. Bár Ricardo modellje statikus szemléletű, a smithi gondolatokra visszautalva a komparatív előnyök elképzelését akár dinamikus szemléletbe is helyezhetjük, hiszen a mindenki számára előnyös specializáció révén a korábban alacsony tudással rendelkező szereplők is olyan tudást halmozhatnak fel, amely hosszabb távon biztosíthatja a vezető szerepet az adott termelési részfolyamat tekintetében. A komparatív előnyök e dinamikus értelmezése rámutat arra is, hogy a modern növekedésemélet mellett a térgazdaságtan mai irányzatának gyökerei is megtalálhatóak a klasszikus közgazdaságtan fontosabb gondolatai között.

A klasszikus közgazdaságtan tehát tartalmazza mindazokat az építőköveket, amelyek a későbbiekben a gazdasági növekedés vagy a térgazdaságtan fontos elemeivé váltak. A jelen dolgozat szempontjából a legfontosabb ilyen építőelem a tudás szerepének hangsúlyozása. Bár a későbbi rendszerező irodalom nem elsősorban a tudás, mint központi tényező szerepét emelte ki a klasszikusok munkájából, látható, hogy ez a gondolat szerves részét képezi a gazdaságról alkotott elképzeléseiknek. Smith arra mutatott rá, hogy a tudás felhalmozódása a munkamegosztás alapja, és a tudás felhalmozódásának éppen a munkamegosztás jelenti az egyik fontos forrását. Ricardo elmélete a komparatív előnyökről aztán kiegészíti

ezt a gondolatot azzal, hogy tudás-felhalmozáson és specializáción keresztül a gazdasági növekedéshez vezető út valamennyi szereplő számára nyitva áll, függetlenül attól, hogy a kezdeti állapotban hatékonysága, azaz a már felhalmozott tudás mennyisége hogy viszonyul más szereplők felhalmozott tudásához.

2.2.2. A neoklasszikus és a keynesi közgazdaságtan

A marginalista forradalom és a nyomában kialakuló, neoklasszikusnak nevezett közgazdasági irányzat szemléletmódja alapvetően eltér a klasszikus közgazdaságtan kérdésfelvetésétől. Míg utóbbiak elsősorban nemzetgazdasági szinten vizsgálódtak, addig az előbbi fókuszában az egyén és a vállalat, a gazdaság egyedi szereplői állnak. A szemléletmódnak ez a lényeges megváltozása egyben azt is eredményezte, hogy a neoklasszikus közgazdaságtan számos lényeges eredménye ellenére a tudás, mint a gazdasági növekedés egyik alapvető mozgatórugója kikerült az érdeklődés középpontjából.

Természetesen ez egyáltalán nem jelenti azt, hogy a tudás, mint fontos kategória eltűnt volna a közgazdasági elemzésből, inkább arról van szó, hogy a szemléletmód megváltozása egyben a dinamikus kérdések háttérbe szorulását és azáltal a statikus szemlélet előretörését is jelentette, s egy ilyen keretben a tudás szükségszerűen külső, exogén faktorként jelenik meg, hiszen, a tudás felhalmozása időbeli, dinamikus folyamat. A tudásnak ezt az exogén szerepét nagyon jól példázza a termelési függvény és a neoklasszikus döntésemélet közötti kapcsolat. A neoklasszikus vállalat termelési-kínálati döntését egy olyan keretben hozza meg, amelyben a technológia adott, s csupán a termelési tényezők nagyságát tudja megváltoztatni. A technológia természetesen tetszőleges lehet, s a termelési függvény technológiai paramétereinek megváltoztatásával a technológia változását is követni tudjuk, lényegi szempont azonban, hogy ebben a keretben a technológia változása exogén módon, kívülről érkezik.

Mindazonáltal a neoklasszikus közgazdaságtan semmiképp nem tekinthető visszalépésnek a tudás gazdasági szempontú elemzése tekintetében. A megváltozott szemléletmód új, fontos kérdések megválaszolását tette lehetővé, ami egyben terepet biztosított ahhoz is, hogy a modern növekedéseméletben a tudás szerepe ismét visszakerüljön a közgazdasági gondolkodás homlokterébe. Ezt kitűnően példázza következő gondolati lépésünk, Solow neoklasszikus növekedési modellje.

A keynesi forradalmat szokás a neoklasszikus közgazdaságtan záróakkordjaként definiálni, ugyanakkor más vélemények szerint a neoklasszikus közgazdaságtan nem zárult le Keynes színrelépésével. Dolgozatunk témája szempontjából a keynesi közgazdaságtan hasonlóan marginális jelentőségű, mint a neoklasszikus közgazdaságtan. Ennek oka az, hogy a keynesi közgazdaságtan, a makroökonómiai elemzés alapjainak lerakásával ugyan a közgazdaságtan figyelmét a mikroszintről visszaterelte a gazdaság makroszintű folyamaira, azonban az elemzési időhorizont jellemzően a rövid táv maradt. Ezzel párhuzamosan pedig a gazdasági növekedés (pontosabban fogalmazva a gazdasági fluktuációk vagy üzleti ciklusok)

fő mozgatóerőit nem a kínálati oldal, hanem a keresleti oldal tényezői között kereste. Így a keynesi modell elsősorban a beruházások, a fogyasztás, a kormányzati vásárlások, egy szóval a kereslet autonóm tényezőinek szerepét vizsgálja és a tudás felhalmozása, amely elsősorban a gazdaság kínálati oldalát érinti, kívül marad az elemzés területén. Így tehát a keynesi közgazdaságtan kapcsán is hasonló következtetést fogalmazhatunk meg, mint a neoklasszikusok esetében: eredményei kétségtelenül újak és fontosak, azonban rövid távú szemléletmódja okán a tudás szerepe nem jelenik meg markáns tényezőként.

2.2.3. A modern növekedéstudomány kiindulópontja: a Solow modell

A gazdaság egészének hosszabb távú vizsgálata, immár a marginalista és a keynesi elvek alapján újragondolt, módszertanilag szofisztikált formában Robert Solow és Trevor Swan neoklasszikus növekedési modelljeivel került vissza a közgazdaságtan fő áramlatába (Solow, 1956, Swan, 1956). Egészen pontosan Solow egy olyan növekedési modellt vázolt fel, amely a neoklasszikus elméletből eredeztethető általános egyensúlyi fogalmakra építve, azonban makroökonómiai szemléletben tárgyalja a gazdasági növekedés kérdését. E modellben a termelést három tényező, a munka, a tőke és e kettő szolgáltatáit kombináló technológia határozza meg.

A Solow-féle növekedési modell alapverziója rögzített technológia mellett a munka és a tőke szerepét vizsgálja a gazdasági növekedés folyamatában. Ebben az esetben a tőkeintenzitás (a tőke- és munkafelhasználás hányadosa) és ezzel együtt az egy főre eső kibocsátás mindaddig változik (nő vagy csökken), amíg a kamatszint – a tőke hozadéka – meg nem egyezik (nagyobb vagy kisebb) a népesség növekedési üteme és az amortizációs ráta összegével. Amint a tőkeintenzitás eléri ezt a stabil egyensúlyi helyzetet és ezzel együtt az egy főre jutó kibocsátás sem változik: a tőkefelhalmozás pusztán arra elegendő, hogy az amortizáció miatti veszteséget és a népesség növekedéséből fakadó pótlólagos tőkeigényt kielégítse. Ez a következtetés első pillantásra kissé borúlátónak tűnik a gazdasági növekedés szempontjából, azonban fontos látni, hogy csak adott, változatlan technológiai szint mellett igaz. Abban az esetben, ha a technológia javul, az egyensúlyi helyzet magasabb egy főre jutó kibocsátás mellett jön létre, ami így értelemszerűen növekszik. Amennyiben a technológia folyamatos javulást mutat, úgy az egy főre jutó kibocsátás folyamatosan növekedhet.

A Solow modellt Ramsey (1928) modelljét alapul véve Koopmans (1965) módosította úgy, hogy az exogén megtakarítási ráta helyett a háztartások előretekintő, hasznosság-maximalizációs döntése generálja megtakarítások pályáját, ezáltal a megtakarítások és a beruházások dinamikus interakciója is vizsgálható a modellben. Ami az egyensúlyi növekedési pályát illeti, a kibővített modell is az eredeti Solow-moddellel analóg eredményekre vezet.

A Solow modell tehát a dolgozat szempontjából már lényegi következtetéseket hordoz. A vizsgálat szempontjából két időtávot célszerű megkülönböztetnünk: a középtávot és a

hosszú távot. ⁶ A két időtáv közötti különbséget az adja, hogy középtávon a technológia rögzített, hosszú távon azonban változhat. Míg középtávon a gazdasági növekedés forrása lehet a tőkeállomány bővülése, addig hosszú távon kizárólag a technológia javulása útján érhető el növekedés.

Ez az eredmény pontosan rímel Smith korábban idézett gondolataira. Mind Smith, mind pedig a Solow modell egyik lényegi mondanivalója az, hogy a tudás felhalmozása alapvetően szükséges tényezője a gazdaság hosszú távú növekedésének, vagyis a nemzetek jólétének, gazdagságának. A két megközelítés közötti különbség abban áll, hogy Smith a tudás felhalmozását a munkamegosztással kapcsolja össze, addig a Solow modellben a tudás felhalmozása a technológia javulását eredményezi, és ezáltal vezet hosszú távú növekedéshez. A munkamegosztás fejlődése azonban tekinthető a technológiai fejlődés egy speciális formájának, sőt, Smith maga is arról ír, hogy a munkamegosztás egyik legfontosabb szerepe a jobb, hatékonyabb munkavégzés kialakítása, így a smithi és a solow-i megközelítések ebből a szempontból ekvivalensnek tekinthetők.

Ennél pontosabb képet is kaphatunk, amennyiben a Solow-modellt kiegészítjük úgy, hogy a technológia időbeli alakulására valamilyen exogén mozgásegyenletet írunk fel, így a technológiai haladás explicite megjelenik a modellben. A legegyszerűbb ilyen lehetőség, ha a technológia valamilyen konstans növekedési rátáját tételezzük fel. Könnyen bebizonyítható, hogy ebben az esetben az egy főre jutó kibocsátás egyensúlyi növekedési rátája meg fog egyezni a technológiai haladás ütemével. Az eredmény általánosítható, vagyis a technológiai haladást leíró folyamat paraméterei határozzák meg az egy főre jutó kibocsátás egyensúlyi növekedési ütemét. Ez az eredmény megerősíti a korábban bemutatott smith-i gondolatokat, bizonyos szempontból tekinthető azok formalizált, egzakt bizonyításaként.

Úgy tűnik, hogy a neoklasszikus növekedési modell egyszerűsége ellenére rendkívül tetszetős és az intuíciót alátámasztó eredményeket ad. Két fontos momentum adódik ugyanakkor, ami ezt a képet árnyalja. A neoklasszikus modellel kapcsolatos két fő probléma közül az egyik, hogy az empiria próbáját csak igen szűk keretek között állja ki, a másik, ezzel összefüggésben pedig, hogy bár a technológiai fejlődés szerepét hangsúlyozza, annak alakulásáról nem mond semmit: a technológiát leíró folyamat exogén adottság a modellben.

A két probléma, úgy tűnik, szorosan összefügg egymással. A növekedéelmélet egyik legfontosabb célkitűzése éppen az, hogy az országok között megfigyelhető – értelemszerűen a növekedési oldalon tapasztalható – különbségeket megmagyarázza. A neoklasszikus modell egy fontos tanulsága, hogy azonos technológiai fejlődési ütemet tekintve a gazdaságok idővel konvergálnak egymáshoz, mind az egy főre jutó kibocsátás, mind a növekedési ráta tekintetében. Ennek egyszerű oka, hogy az alacsonyabb tőke-munka arány mellett működő tipikusan szegényebb országok növekedési rátája magasabb, míg a magasabb tőke-munka arány mellett működő országok növekedési rátája alacsonyabb. Így tehát a szegény országok gyorsabban nőnek és értelemszerűen felzárkóznak a fejlettebbekhez.

⁶Rövid távon tipikusan rögzítettnek feltételezzük a tőkeállományt, ami viszont a Solow modellben változik, így a legpraktikusabb terminológia a közép- és hosszú táv elnevezés használata.

Ezek az eredmények azonban ellentmondanak a tapasztalatoknak. Romer (1987, 1988) vizsgálatai rámutatnak, hogy a növekedési ráták az egyes országok tőkeállományának nem csökkenő, hanem növekvő függvényei. Ennek következtében nem a növekedési ráták és a kibocsátás konvergenciája, hanem éppen ellenkezőleg, azok divergenciája figyelhető meg. Természetesen ez a probléma első látásra feloldható úgy, hogy a technológiai haladás különböző növekedési ütemeit tételezzük fel a különböző országokban, így minden ország növekedési lehetőségeit a saját technológiai haladásának üteme határozza meg. Ez az érvelés azonban figyelmen kívül hagyja a technológia diffúziójának szerepét, hiszen ha feltételezzük a tőke és a tudás áramlását az egyes gazdaságok között, akkor a technológiai haladás üteme is kiegyenlítődik. Barro és Sala-i-Martin (1991 és 1992) tanulmányai arra mutatnak rá, hogy a konvergencia az országok közötti vizsgálatokkal szemben jól megfigyelhető az Amerikai Egyesült Államok államai között, ami nem meglepő, hiszen a tőke, a munka és a technológia szabad áramlása az azonos technológiai növekedési ütemet biztosíthatja is.

A fenti megoldással (eltérő technológiai fejlődési ráták feltételezése a különböző országokban) azonban a kérdés csupán elnapolásra került. Hiszen ha az országok közötti jelentős különbségek abból fakadnak, hogy a technológia más ütemben fejlődik az egyes országokban, akkor mi okozza az eltérést a technológiai fejlődés ütemében? A neoklasszikus növekedési modellek exogén technológia-reprezentációja nem volt elégséges e kérdés megválaszolásához, így mindenképpen szükség volt olyan modellek kifejlesztésére, amelyek a technológiai haladást endogenizálják, azaz a technológia változását a modellek megmagyarázzák, így lehetővé téve a fejlődési ütem eltéréseinek vizsgálatát.

2.2.4. Endogén növekedésmélelet

A neoklasszikus növekedési modellek, bár szerepük vitathatatlan, nem bizonyultak elegendőnek ahhoz, hogy a gazdasági növekedés alapvető kérdéseit teljes körűen megválaszolják. Az empirikus tapasztalatok indították útjára az endogén növekedésméleletet, amely arra tesz kísérletet, hogy a technológiai haladást beépítse a növekedési modellekbe.

Technikai értelemben arról van szó, hogy a neoklasszikus modell alapvető jellemzőjeként értelmezhető csökkenő hozadékot kell a modellekből eliminálni. A neoklasszikus modell fő elve ugyanis éppen az, hogy a tőkeállomány bővülésével a tőke határtermelékenysége és (a tökéletesen versenyző piacok feltevéséből fakadóan) ezáltal a tőkeberuházások megtérülése (a reálkamatláb) is csökken. A csökkenő megtérülés a megtakarítások és (ismét a tökéletes piacok miatt) egyúttal a beruházások csökkenéséhez vezet, ami a tőkeállomány egyre kisebb mértékű növekedését eredményezi. Ahhoz tehát, hogy a növekedés valóban belülről fakadjon, a csökkenő hozadékot kell kiküszöbölni a modellekből, ami az egyensúlyi tendenciákat adja.

Praktikus szempontból az endogén növekedésmélelet központi koncepciója, hogy a technológiai fejlődés ütemét a modellek belülről magyarázzák. Az elnevezés is innen származik: a technikai fejlődés és az emberi tőke felhalmozásának explicit modellezésével kísérlet meg

választ adni a gazdasági növekedés kérdéseire. A technológiai fejlődés ezekben a modellekben a gazdasági szereplők döntéseinek következményeként alakul, illetve az is megfogalmazódik, hogy a tudás és a technológia felhalmozásához és fejlődéséhez beruházásokra, vagyis erőforrásokra van szükség (Valentinyi, 1995). Ugyanakkor az is egy fontos szempont, hogy míg a neoklasszikus modellek a technológiai haladás ütemét exogénnek, így valamennyi országot egyformán érintőnek tételezték fel, egy endogén növekedési modellben a technológia terjedésének, diffúziójának a szerepe is felmerül (Romer, 1994).

Az endogén növekedésemélet egyik alapvető kiindulópontja Lucas (1988) tanulmánya, melyet a szerző további munkái követtek (Lucas, 1990, 1993). Modelljében Lucas az emberi tőke felhalmozására koncentrál. A korábbi exogén technikai haladással működő modelleket annyival egészíti ki, hogy a munka termelékenységeként értelmezett emberi tőke felhalmozásához effektív erőforrásokra van szükség. Egészen pontosan a rendelkezésre álló munkaerő felhasználható a termelésben, de az emberi tőke felhalmozásához is munkaerőre van szükség (kutatás-fejlesztés, tanulás). Így a termelés hatékonyságának változása, vagyis a technológiai haladás üteme attól függ, hogy a gazdasági szereplők miként osztják meg a rendelkezésre álló munkaidejüket a „hagyományos” termelő tevékenység és az emberi tőke felhalmozása között.

Ez a megközelítés aztán az ún. tudás-termelési függvény koncepciójához vezetett el, amelyben az új tudás létrejöttét különböző tényezőkhöz kötik.⁷ A tudás-termelési függvények, vagy másképpen a tudás vagy technológia felhalmozását leíró összefüggések (egyenletek) egyik legfontosabb tényezője többnyire a tudás (emberi tőke) vagy technológia már elért szintje. Valentinyi (1995) kiemeli, hogy ennek lényege éppen az, hogy az emberi tőke felhalmozása egy olyan folyamat, amely a meglévő tudás átadásán, így a gazdasági szereplők közötti kapcsolattartáson alapul. Így logikus, hogy a már elért tudásszint meghatározó a további felhalmozás folyamatában. Amellett, hogy ez az érv alátámasztja a disszertáció témájának relevanciáját, fontos kiemelni, hogy az emberi tőke állományának magyarázó változóként történő bevonása a tudás-termelési függvénybe nem csupán a kapcsolattartás szükségességén alapulhat, hanem azon is, hogy a már megszerzett ismeretek egyfajta hatékonysági többletet jelentenek a további felhalmozásban. Cohen és Levinthal (1989, 1990) irányadó munkáikban azt emelik ki, hogy a vállalatok kutatás-fejlesztési tevékenységének a tudás-felhalmozás mellett egy olyan feladata is van, hogy az iparág fejlődésével lépést tartson, azaz, hogy megkönnyítse a vállalaton kívülről érkező információk feldolgozását és felhasználását. A már felhalmozott tudás elősegíti az új ismeretek felhalmozását.

A korábban tett megállapítást itt megismételve tekinthetjük úgy a tudást, mint egy adat- vagy információ elemek közötti hálózatot. A tudás így a befogadott információk függvényében hatványozottan (növekvő ütemben) növekszik, hiszen a hálózat elemei közötti potenciális kapcsolatok száma is így változik: minden egyes új elem a tudáshálózatot jelentős mértékben képes növelni, hiszen új kapcsolódási lehetőségek sokaságát hozza létre. Ez

⁷ Empirikus vizsgálatát lásd pl. Pakes és Griliches (1984) vagy Griliches (1990) munkáiban. A tudás-termelési függvény és az endogén növekedési modellek közötti kapcsolatáról bővebben Abdih és Joutz (2005) ír.

a mérték pedig annál nagyobb, minél nagyobb a kiindulásul szolgáló hálózat, azaz minél szélesebb a már meglévő tudásbázis.

Arrow (1994) összegzése szerint az endogén növekedési modellek egy jelentős csoportjában a tudás termelése csupán a már meglévő tudás mennyiségétől függ, ami összhangban áll az előző gondolattal, azonban a termelés és a tudás közötti összefüggéseket csak részben jeleníti meg: a tudás inputja a termelésnek, a tudás felhalmozásának inputja azonban csupán maga a tudás. A tudás-termelési függvényekben az esetekben egytényezős, és nem szerepel benne például a munkafelhasználás. Ilyen modell Arrow nagy jelentőségű learning-by-doing modellje (Arrow, 1962), vagy Silverberg és Lehnert (1994) modellje. Ezzel szemben egy fontos további láncszemet jelentenek azok a modellek, ahol a tudás termelési függvényében már megjelennek más erőforrások is, mint a munka vagy tőkeáfordítás. A korábban hivatkozott Lucas (1988) modell vagy Shell (1967) modellje tartozik ebbe a kategóriába.

Az emberi tőkére és az emberi tőke ilyen vagy olyan módon történő felhalmozására épülő modellekkel szemben az endogén növekedélmélet modelljeinek másik nagy csoportja az innovációt, az új termékek vagy technológiák létrehozását/létrejöttét állítja az elemzés központjába. Ezen irányvonal mentén tipikusan két részleteiben különböző, lényegét tekintve azonban azonos modellezési módszer található. Az egyik módszer alapját Romer (1990) tökéletlen versenyre épülő dinamikus modellje adja, amely Dixit és Stiglitz (1977) monopolisztikus versenymodelljét alkalmazza dinamikus megközelítésben. Ezek a modellek a kutatás-fejlesztés szerepét úgy építik be, hogy annak eredményei a termékek körének folyamatos bővülését eredményezik. A fogyasztók változatosság iránti igényén keresztül a termékvariánsok számának növekedése egyfajta pozitív externhatást generál, amely ellensúlyozza a termelési tényezők csökkenő hozadékát, és endogén növekedéshez vezet. A megjelenő új termékek ezekben a modellekben nem váltják ki a régieket, csupán az utóbbiak ára csökken.

A másik módszer Grosman és Helpman (1991, 1994) modelljeire épül, ahol a piaci forma hasonlóan a monopolisztikus verseny, azonban az innovációt nem a termékkör szélesedése, hanem a termékek minőségének javulása eredményezi. A rögzített számú termék egyre jobb és jobb minőségben jelenik meg, ami a termelés hatékonyságát is növeli, így itt ez a hatékonysági többlet vezet a csökkenő hozadék ellensúlyozásához. Az előző módszerrel ellentétben azonban a jobb minőségű termékváltozatok kiszorítják a piacról a rosszabb minőségű termékeket. Egy hasonló modellt alkalmazva Aghion és Howitt (1992) a schumpeteri kreatív rombolás elvét alkalmazva (Schumpeter, 1934) felhívják a figyelmet arra, hogy az elavulttá váló technológiák miatti veszteséget is figyelembe kell venni: a magasabb ütemű technológiai fejlődés egyfajta negatív externáliát generál, mivel a vele együttjáró gyors avulás miatt a technológiai fejlődésbe történő beruházások megtérülése csökken. Így könnyen elképzelhető egy olyan állapot, ahol az innováció „túltermelése” jellemző.

A két módszer különbségei ellenére azonos következtetésekre vezet (Barro és Sala-i-Martin, 1995): a kutatási tevékenység számára rendelkezésre álló erőforrások, valamint e tevé-

kenység hatékonysága pozitívan hat a növekedésre, így könnyen bizonyítható, hogy a szegényebb országok miért mutatnak lassabb növekedést. A két módszer azonos abban is, hogy a korábbi tökéletes versenypiacok helyett monopolisztikus versennyel dolgoznak. Ennek az az oka, hogy amint az innováció kerül előtérbe – akár a növekvő termékszámot, akár a minőségi javulást tekintjük innovációnak –, annak a vállalatok szempontjából csak akkor van értelme, ha a termékeiket meg tudják különböztetni a többi cég termékétől. Ez viszont azt eredményezi, hogy valamekkora monopolerővel kell rendelkezniük, vagyis nem lehetnek végtelenül kicsinyek, mint a tökéletes versenypiac vállalatai. Ennek a megkülönböztetésnek az innovációból fakadó profitlehetőségek kiaknázása miatt van jelentősége. A legalábbis minimális monopolpozíció eléréséhez azonban arra is szükség van, hogy a vállalatok célja a növekedés legyen, tehát hogy létre is jöhessenek ezek a nem végtelenül kicsiny vállalatok. Ezt az ösztönzést pedig éppen a növekvő hozadék adhatja meg, ami, mint láttuk, az endogén növekedéelméletben a korábbi csökkenő hozadékot váltotta fel.

2.2.5. Technológiai diffúzió

Az endogén növekedélmélet fő kérdésével párhuzamosan (honnan ered a technológiai fejlődés?) felmerül a technológia terjedésének, diffúziójának kérdése is. Mukoyama (2004) a technológiai fejlődés kapcsán kétlépéses folyamatról beszél: az első lépés az innováció, amikor az újítás bekerül a gazdasági folyamatokba, a második lépés pedig az újítás elterjedése, azaz az adaptálás és diffúzió. Rogers (2003) megjegyzése szerint a technológiai diffúzióval foglalkozó irodalom óriási méretű, mintegy 5.200 ilyen témájú publikációt számolt össze. Értelemszerűen itt nem vállalkozhatok ennek az irodalmi korpusznak akár csak vázlatos ismertetésére is, így az általam fontosnak tartott pontokat emelem ki az alábbiakban, szükségszerűen ad-hoc jelleggel.

A technológiai diffúzióval foglalkozó empirikus szakirodalom egyik alapvető következtetése a diffúzió S-görbét követő, vagy másképpen logisztikus mintája (lásd pl. Griliches, 1957; Davies, 1979; Gort és Klepper 1982). A diffúziós folyamat a legelterjedtebb klasszifikáció alapján öt fázisra osztható (Rogers, 2003).

- Az első fázisban jelentkeznek az innovátorok, akik az újítás első alkalmazói. Ez a csoport speciális jellemzőkkel írható le, amely alkalmassá teszi e szerep betöltésére: többnyire hajlandóak magasabb kockázatot vállalni, illetve fontos kapcsolatokkal rendelkeznek tudományos források, valamint más innovátorok felé. Ebben a szakaszban jelenik meg az innováció a gazdaság/társadalom egyes pontjain, amely aztán a diffúzió bázisát jelenti.
- A második fázis a korai adaptálók időszaka, akik továbbra is az újdonságot elfogadók első képviselői között vannak. Fontos véleményvezetői szerepük van, amit az innovációk korai alkalmazásával/adaptálásával tudnak erősíteni.

- A harmadik fázisban jelenik meg a korai többség, akik az előző fázis során már teret nyert újdonságot a véleményvezetők alapján fogadják el. Ez a fázis rendszerint lassabb, ugyanakkor az adaptálók száma is magasabb.
- A negyedik fázisban a késői többség fogadja el az innovációt, akik kevésbé a véleményvezetőkre, inkább a korai többségre reagálva kezdik alkalmazni az újdonságot. E fázis során az adaptáció sebessége lassul, ahogy a piac egyre telítettebbé válik.
- Az ötödik fázisban a lemaradók veszik át az újdonságot, akik többnyire kis fogékony-ságot mutatnak az újdonság iránt. Ebben a fázisban telítődik a piac, a diffúzióban rejlő lehetőségek, és ezáltal a diffúzió dinamikája is kifulladásra kerül.

Az empirikus kutatásokkal párhuzamosan a diffúzió elméletével foglalkozó szakirodalom a fent bemutatott logisztikus diffúziós minta magyarázatára próbál plauzabilis magyarázatot találni. Attewell (1992) a diffúzióval foglalkozó elméletek két típusát különbözteti meg: mikro- és makroszintű vizsgálatokat. A mikroszintű, vagy egyéni perspektívában az egyedi szereplők adaptációs készsége, motivációi képezik a vizsgálat tárgyát, míg a makroszintű vizsgálatok értelemszerűen egy társadalom, gazdaság vagy szélesebb értelemben egy adott populáció egésze szintjén keresik a választ a diffúzió kapcsán felmerülő kérdésekre.

Praktikus szempontból ezen a ponton merül fel először a hálózatok szerepe a technológiai haladás folyamatában: az innováció diffúziója szükségszerűen az egyedi gazdasági szereplőket összekötő kapcsolati hálókön keresztül zajlik. Az ezzel kapcsolatos szakirodalom tárgyalását, tekintve a téma kiemelt szerepét a disszertáció tematikájában, egy későbbi, részletes fejezetpont tartalmazza.

2.2.6. Tudás-spilloverek és lokalitás

A technológiai diffúzió elsősorban elméleti vonatkozású szakirodalma mellett egy másik, főként empirikus irányzat is fontos helyet kapott az innovációval és a növekedéssel kapcsolatos közgazdasági gondolkodásban, nevezetesen a tudás terjedésének, „tovagyűrűzésének” – vagy a hazai terminológiában is meghonosodott angol kifejezéssel élve tudás-spilloverek – irodalma. Ez az irodalmi irányvonal a technológiai diffúzió „mechanikus”, a tudás áramlására fókuszáló szemléletével szemben a tudás áramlása során keletkező extern hatások kérdésére koncentrálnak. Griliches (1979, 1992) az elsők közt hívta fel a figyelmet arra, hogy a gazdasági szereplők által létrehozott új tudás mások által is használhatóvá válik, mivel ez a tudás kodifikálható és transzferálható a vállalatok vagy más szervezetek között. Így a vállalatok vagy más szervezetek saját, belső tudás-termelése pozitív extern hatásokkal bír és az innovációs tevékenységet az adott szervezetenél szélesebb körben mozdítja elő.

A spilloverek kutatásában természetesen az egyik legfontosabb sarokkő a tudás és a tudás áramlásának empirikus megragadása. Krugman (1991) megjegyzi, hogy a spilloverek empirikus vizsgálata azért lehetetlen, mert a tudás nem hagy maga után nyomot, amelyet fel

lehetne fejteni. E pesszimista kijelentés ellenére a kutatók több olyan lehetőséget is kidolgoztak, amellyel ezek a nyomok felderíthetőek. Az első és legfontosabb ilyen lehetőséget a szabadalmi adatbázisok biztosították (és biztosítják most is): az itt fellelhető, szabadalmi hivatkozásokra vonatkozó információk (természetesen alkalmasan feldolgozva) megmutatják, hogy a technológiai tudás milyen jellemzők szerint terjed a gazdasági szereplők között. A szabadalmi hivatkozások mellett a szabadalmi kooperációk vizsgálata is lehetővé vált (erre a módszerre épül a jelen disszertáció empirikus tartalma), továbbá olyan adatbázisok is elérhetőek, amelyek segítségével a munkaerő áramlása révén megvalósuló tudás spilloverek követhetőek nyomon.⁸

Szabadalmi hivatkozásokat alkalmazva Jaffe (1986) arra a következtetésre jut, hogy egy vállalat kutatás-fejlesztési termelékenységét meghatározó tényezők között lényeges szerepet játszik a technológiailag közel álló vállalatoktól származó tudás. Felmerül azonban ebben a vonatkozásban a térbeliség szerepének kérdése: számít-e a térbeli koncentrátság az innovációs tevékenység hatékonyságát tekintve, vagy sem? Ez a felvetés szorosan összefügg azzal a kérdéssel, hogy a tudás milyen módon és milyen közvetítőkön keresztül jut el egyik vállalattól a másikhoz. Minél inkább tacit jellegű tudásról van szó, annál fontosabb a személyes kapcsolat a tudás átadója és átvevője között, ennek következtében a térbeli közelség, mint a személyes kapcsolattartást megkönnyítő tényező, lényeges szerephez juthat. Ezzel párhuzamosan a tacit tudás jellemzően magukban az emberekben testesül meg, így a munkaerő mobilitásán keresztül megvalósuló tudás-áramlás is tartalmaz térbeli korlátokat, amennyiben a munkaerő mobilitása bizonyos okoknál fogva (kulturális korlátok, személyes kapcsolathálók, stb.) térben koncentrált.

Jaffe (1989) a Griliches-féle tudás-termelési függvény egy bővített változatát felhasználva a spilloverek térbeli dimenzióját vizsgálja. Eredményei azt mutatják, hogy azokban a régiókban (elemzési egységekként USA államokat használ), ahol a tudás-generáló inputok (kutatás-fejlesztési kiadások, kutatásban dolgozó munkaerő, stb.) szintje nagyobb, ott a szabadalmi tevékenység is magasabb. Feldman (1994) pontosítja Jaffe (1989) módszerét: szabadalmak helyett új piaci bevezetések vizsgálva megerősíti a korábbi eredményeket. Úgy tűnik, hogy a spilloverek térben korlátosak: az új tudás jellemzően abban a régióban fejt ki a korábban említett externális hatását, amelyben létrejött. Anselin és szerzőtársai (1997) a vizsgálatot szűkebb térbeli egységeken is elvégezték és a spilloverek térbeli korlátosságát ezen a szinten is kimutatták.

Jaffe és szerzőtársai (1993) szabadalmi hivatkozásokat használva szintén kimutatták a spilloverek térbeli koncentrációját. Eredményeik azt mutatják, hogy különböző földrajzi szinteken és a szervezetek típusa szerint korrigálva is kimutatható a térbeli korlát a tudás áramlása során. Természetesen érdekes kérdés az is, hogy ez a térbeli koncentrátság hogyan alakul időben. Logikusan azt várnánk, hogy idővel ezek a korlátok leépülnek, ahogy a tudás kodifikálásra kerül és a tacit elemek áramlásával kapcsolatos akadályok is oldódnak (példá-

⁸A szabadalmi hivatkozások első alkalmazását lásd: Trajtenberg (1990). A szabadalmi együttműködésekről lásd pl. Maggioni és Uberti (2010), Sebestyén és Parag (2010), a munkaerő áramlása kapcsán pl. Boschma és szerzőtársai (2009).

ul a kapcsolati hálókön keresztül vagy a munkaerő mobilitása révén egyre több vállalathoz jut el az új tudás). Jaffe és Trajtenberg (1996) eredményei megerősítik ezt a feltevést, kimutatva, hogy a térbeliség szerepe idővel csökken. Ezen felül azt is kimutatják, hogy ez az időbeli hatás lényegesen erősebb azokban az iparágakban, ahol a tudás avulása gyors (elektronika, optika, nukleáris technológia). Más tanulmányok arra hívják fel a figyelmet, hogy a spilloverek térbelisége markánsabb azokban az ágazatokban, ahol a tudás fontos kompetitív faktor (Audretsch és Feldman, 1996), vagy ahol a felhasznált tudás alapvetően tacit (Sorenson, 2005). Természetesen a tudás tacit jellegének szerepe és az idődimenzió jelentősége szorosan összefügg: egy technológiai innováció és a hozzá kapcsolódó tudáshalmaz kezdetben jellemzően tacit elemeket tartalmaz, míg az idő előrehaladtával a tudás nagyobb része kodifikálásra kerül. Ez a dinamikus folyamat aztán a spilloverek előtt álló térbeli korlátok lebomlásához vezet.

Röviden összefoglalva a tudás-spilloverekkel foglalkozó irodalom tapasztalatait, azt látjuk, hogy a gazdaság egyes pontjain létrejövő új tudás, legalábbis időlegesen, lokálisan terjed. Az innovációs tevékenység térbeli koncentrációja így jól magyarázható a tudás terjedésének térbeli korlátaival. Ez ugyanakkor rámutat a gazdasági növekedés lokális dimenziójának kérdésére. Ahogy a tudás gazdasági növekedésben betöltött szerepe kapcsán már rámutattunk, a tudás a gazdaságban lokális pontokból indul ki – a spilloverek lokalizáltsága pedig arra a következtetésre vezet, hogy a növekedés elsősorban lokális jelenség. Helyi agglomerációk, kiemelkedő innovációs tevékenységet nyújtó városok (vagy sokszor csak vállalatok) jelentik a gazdasági növekedés húzóerejét, amely azután kisebb-nagyobb mértékben tevődik át más területekre (Storper, 1995).

Részben ez a fő konklúzió vezetett ahhoz, hogy a közgazdasági irodalomban a térbeliség kérdése előtérbe került. Az empirikus és az elméleti irodalom egyaránt széles körűen foglalkozott azzal a kérdéssel, hogy milyen ösztönzők találhatóak, amelyek a vállalatok számára előnyössé teszik a térbeli koncentrációt, ezáltal hozzájárulva a helyi agglomerációk kialakulásához.

Marshall (1890) nyomán az első vizsgálatok arra keresték a választ, hogy milyen helyi méretgazdaságossági hatások lehettek fel, amelyek a helyi agglomerációba belépő vállalatok számára előnyöket kínálnak. Összefoglaló néven ezeket agglomerációs externáliáknak (vagy helyi méretgazdaságossági hatásoknak) nevezi a szakirodalom és alapvetően két típusa különböztethető meg (Johansson és Forslund, 2008). Az első típust lokalizációs externáliának nevezzük (localization economies), és olyan hatásokra utal, amelyek külső hatásnak számítanak egy vállalat esetében, de a vállalatok lokális csoportja számára már nem. Ebben az esetben a vállalatok hasonló tudásbázisa katalizálja az agglomerációs folyamatot: azon vállalatok tudnak hatékonyabban kommunikálni egymással, akik ugyanazon technológiai területen specializálódtak és működnek. A tudástranszfert a közös tudás alap is támogatja, így az új információ és tudás gyorsabban terjed. A vállalatok érdekeltek lesznek abban, hogy mindezen előnyök kiaknázása érdekében egymáshoz közel helyezkedjenek el (Johansson és Forslund, 2008; Weterings és Boschma, 2006; Pirrelli, 2006). Az ilyen típusú

externáliák eredménye a specializáció, melyet a hasonló vagy azonos technológiai területekre fókuszáló vállalatok klasztereinek megjelenésével figyelhetünk meg. A lokalizációs externáliákkal foglalkozó empirikus eredmények vegyesek. Feldman (1999) szerint ez annak tudható be, hogy nehéz elkülöníteni a vállalatok belső méretgazdaságossági hatásaiból fakadó térbeli koncentrációt a dinamikus agglomerációs erőktől egyrészt, másrészt pedig a helyi erőforrás-ellátottság szerepét is figyelembe kell venni.

A helyi méretgazdaságossági hatások másik típusát urbanizációs externáliáknak hívjuk (urbanization economies), bár ezekre az externális hatásokra Jacobs-externáliákként is hivatkozik a szakirodalom. Ebben az esetben a koncentrációból fakadó előnyök az adott térség (régió, város) méretéből fakadnak, így a vállalatok és az iparágak egésze számára is külső hatásként jelennek meg. Ekkor nem a hasonlóság, hanem éppen a különbség az agglomeráció fő mozgatóereje. Jacobs (1969) szerint a nagyvárosok éppen általa válnak vonzó helyszíneivé az innovációs aktivitásnak, mert a közösség sokfélesége bőséges forrássá szolgál az új ötleteknek és az asszociatív újításoknak. Ebben az esetben a vállalatok nem feltétlenül a tudástranszfer könnyedsége miatt érzik előnyösnek, hogy egymás közelébe települjenek, hanem azért, mert a nyüzsgő városi atmoszféra kivételes innovációs lehetőségeket biztosít számukra. Weterings és Boschma (2006) hozzáteszi, hogy a tudásbázisok sokfélesége nemcsak az innovativitás szempontjából fontos, hanem nélkülözhetetlen forrását jelenti az interaktív tanulásnak is, amely szintén az innováció egyik fontos tényezője. Feldman (1999) kiemeli, hogy az empirikus vizsgálatok tipikusan megerősítik az urbanizációs externáliák jelentőségét az agglomerációs folyamatokban.

Mindkét fenti agglomerációs externália esetén a fő hangsúly a helyi tudás szerepén van: a tudás, akár a specifikus fókusz, akár a sokféleség jelenti a vonzerőt, fontos tényező az agglomerációs folyamatokban. Feldman és Lichtenberg (1997) a tudás tacit jellegének hatását vizsgálják ebben a kontextusban. Eredményeik azt mutatják, hogy minél inkább tacit jellegű tudást tartalmaz egy kutatási projekt, az annál inkább centralizált a térben. Caballero és Jaffe (1993) eredményei a tudás amortizációjának szerepét emelik ki: minél gyorsabb a tudás avulása egy ágazatban, a térbeli koncentráció annál erősebb, mivel ez egy olyan lehetőséget jelent, amellyel az újítók képesek lehetnek kutatási költségeiket csökkenteni. Liebeskind és szerzőtársai (1995) a tudás hozamainak kisajátíthatóságának kérdését vizsgálják. Eszerint a gyors technológiai fejlődés arra ösztönzi a vállalatokat, hogy alkalmas egyensúlyt alakítsanak ki a kooperáció és a verseny között: a versenyre az innovációból fakadó lehetséges nyereségek kihasználása miatt van szükség, a kooperációra viszont azért, hogy a gyors fejlesztési ütemhez szükséges komplementer tudásbázisokhoz is hozzáférjenek. A kooperáció a kölcsönös bizalom alapján működik, amelynek a kialakítását azonban megkönnyíti a térbeli közelség.

Kiemelten ez utóbbi megközelítés az innovációhoz szükséges kooperáció kapcsán, de a lokális méretgazdaságossági hatások valamennyi értelmezése rámutat a személyes kapcsolatok fontosságára. Az egyes interpretációk ugyanakkor sokszor csak odáig mennek el, hogy a helyi agglomerációt egy olyan közegnek fogják fel, ahol a tudás szabadon áramlik, és a

kérdéses határvonal e tudáshoz való hozzáférés tekintetében valamilyen térbeli korlátot jelent.⁹ Breschi és Lissoni (2003) ugyanakkor rámutat arra, hogy a személyes kapcsolatok jelentősége a tudás-áramlásban és ezáltal a helyi agglomerációs hatásokban árnyaltabb megközelítést kíván. Felhívják a figyelmet arra, hogy a térbeli közelséget inkább a társadalmi közelség (social proximity) közelítő változójaként lehet felfogni. A térbeli közelség annyiban fontos, amennyiben hozzájárul a társadalmi kapcsolatok és az azokban foglalt bizalom kialakulásához. Mivel a térbeli közelség a kapcsolatok és a bizalom kialakulását nagy mértékben elősegíti, e kapcsolatok lokálisan sűrűek lesznek és az innovációs (vagy tágabb értelemben gazdasági) aktivitás térbeli koncentrációja olyan színben tűnik fel, mint a tudásspilloverekhez való hozzáférés fontos médiuma. Ez pedig elfedi azt a valós helyzetet, hogy a spilloverek személyes kapcsolatokon és társadalmi hálózatokon keresztül fejtik ki hatásukat, így azok csak annyiban lokálisak, amennyiben a hálózatok is azok. Ezen a gondolati vonalon egyes tanulmányok megmutatják, hogy a tudásspilloverek lokális hatásai csupán a munkaerő immobilitásán alapulnak (Zucker és szerzőtársai, 1994; Almeida és Kogut 1999; Balconi és szerzőtársai, 2004).

Így tehát eljutunk a disszertáció fő témáját jelentő hálózatok kérdésköréhez: a tudás áramlásának és így a technológia diffúziójának legfontosabb terepe az egyének és vállalatok közötti kapcsolatokban található. E kapcsolatok hálózata aztán meghatározza az innováció terjedését és ezáltal a gazdasági növekedést egy adott területen belül és kívül egyaránt: az innováció és a növekedés lokalizáltsága a hálózatok lokalizáltságától függ. A továbbiakban a hálózatokkal kapcsolatos alapvető szakirodalmi ismeretanyag áttekintésére kerül sor.

2.3. Hálózatok és innováció

A hálózatok kutatása komoly múltra tekint vissza, igazán népszerűvé azonban az utóbbi időben vált. A hálózatok tudománya a matematikából ered, amelynek gráfelmélet nevű ága foglalkozik a hálózatok kérdéskörével. A gráfelmélet első megjelenéseként Leonard Euler 1741-es tanulmányát szokták megjelölni, amely a köningsbergi hidak problémájára ad megoldást (Euler, 1741). Euler megoldása azért válhatott alapvetővé a későbbiekben, mivel felismerte azt a tényt, hogy a probléma megoldásához elegendő a hidak számának és végpontjainak ismerete. Így a probléma felírható egy absztrakt, csomópontokból és élekből álló struktúra segítségével, amely struktúrák (csomópontok és élek halmaza) a gráfelmélet vizsgálatának tárgyát képezik. A gráfelmélet mellett az euléri megoldás alapozta meg a topológia, mint matematikai ág megjelenését is.

A gráfelmélet tulajdonképpen a hálózatok matematikai elmélete is egyben, hiszen a gráfokat más szóval hálózatoknak is mondhatjuk. Bizonyos szempontból a hálózati vagy gráfelméleti szemlélet a valóság egy speciális szemüvegen keresztül történő vizsgálatát jelenti. A valóságban előforduló tárgyak, jelenségek, személyek vizsgálhatók azok kölcsönhatásai,

⁹Talán Kaldor (1966) használta elsőként a „mennyből hulló manna” hasonlatot a tudás ilyenfajta felfogása kapcsán.

kapcsolatai segítségével. Ebben az esetben az adott struktúra egy hálózattal írható le és a hangsúly a hálózat elemeiről az azok közötti kapcsolatokra, és e kapcsolatok struktúrájára tevődik át.

A hálózatok speciális perspektívája az utóbbi évtizedben, elsősorban az erdélyi származású fizikus, Barabási Albert-László és munkatársai munkája nyomán vált népszerűvé. Már korábban is felismerték, hogy a bennünket körülvevő világ jelenségei nagyon sok esetben leírhatók hálózati fogalmakkal: út- és közlekedési hálózatok, társadalmi kapcsolatháló, gazdasági (piaci) hálózatok, sejtek hálózatai (pl. neuronok) vagy akár a sejten belüli alkotóelemek (fehérjék) hálózatai. Barabásiék jelentős hozzájárulása abban áll, hogy felfedezték, hogy ezek az egymástól meglehetősen különböző területeken felbukkanó hálózatok azonos szereződési mintákat mutatnak:

„Hasonlóan ahhoz, ahogy a különböző emberek csontváza majdnem megkülönböztethetetlen, rájöttünk, hogy ezek a különböző térképek [hálózatok térképei] egy közös tervrajzot követnek. Friss és lélegzetelállító felfedezések sorozata arra a felismerésre kényszerít bennünket, hogy minden minket körülvevő összetett hálózat szerkezetét és fejlődését meglepően egyszerű és messze mutató természeti törvények irányítják.” (Barabási, 2002, 16-17.o.)


2.3.1. A hálózati struktúra

A hálózati struktúrák kérdéskörét tekintve a vonatkozó szakirodalom egy meglehetősen tisztán azonosítható logikai ívre fűzhető fel. A statisztikai fizika elveivel összhangban a való világ hálózatait eleinte véletlenszerű hálózatoknak fogták fel, ahol a kapcsolatok kialakulása véletlenszerű folyamatot követ. A véletlen hálózatok elméletének kialakulása egy magyar szerzőpáros, Erdős és Rényi (1959) cikkéhez köthető.¹⁰ A véletlen hálózatok egy igen fontos tulajdonsága az, hogy a hálózat elemeinek (a csomópontoknak, vagy másképp csúcsoknak) fokszáma, azaz kapcsolatainak száma Poisson-eloszlást követ. A hálózat ekkor jól jellemezhető egy reprezentatív csomóponttal és a hozzá tartozó átlagos fokszámmal: a szélsőséges fokszám-értékek előfordulásának valószínűsége a (véletlen) hálózatban alacsony. A valós hálózatok véletlenszerűségével kapcsolatosan azonban két fontos probléma is megfogalmazódott a későbbiek során.

Egyfelől a szociológiai vizsgálatok mutattak rá, hogy a társadalmi hálózatok nem adhatók vissza teljes mértékben a véletlen hálózatok segítségével. Ezek a vizsgálatok a társadalmi hálózatokat ún. „kis világokként” írják le, ahol a szorosan összefüggő, összekapcsolt lokális csoportokat áthidaló kapcsolatok kötik össze. Maga az elnevezés arra utal, hogy ezekben a hálózatokban a csomópontok közötti átlagos elérési úthossz relatíve kicsi, miközben a lokális csoportok megőrzik viszonylag éles határvonalait. Travers és Milgram (1969) a Harvard egyetem ismeretségi hálózatát vizsgálva jutott arra a felismerésre, hogy az átlagos elérési út még egy ilyen kiterjedt kapcsolati hálózatban is meglepően rövid, mindössze 5,5

¹⁰A véletlen hálózatok elméletéről ad összefoglalót például Bollobás (2001).

lépés. Barabási (2002) megemlíti, hogy a relatíve rövid átlagos távolságok gondolatát korábban Karinthy Frigyes vette föl egy írásában, ahol meglepően pontosan „előrejelezve” a későbbi tudományos eredményeket, 5 lépéses távolságról ír (Karinthy, 1929). Alapvető referenciának számít ebben a témakörben Granovetter (1973) tanulmánya is, aki a lokális csoportokat összekötő „gyenge” kapcsolatok jelentőségét emeli ki. A társadalmi kapcsolatrendszerek általa felvázolt struktúrája a kis világok reprezentációja. A 2.1. ábra mutat egy ilyen típusú hálózati struktúrát: a sűrű lokális kapcsolatok mellett kevésbé dominánsak a csoportok közötti áthidaló kapcsolatok.



2.1. ábra. Tipikus kis világ hálózati struktúra


A kis világok intuitív elképzelését Watts és Strogatz (1998) formalizálták. Modelljükben két jellemző, a lokális kapcsolatok szerepét mérő klaszterezettségi együttható, valamint a csomópontok közötti átlagos elérési út hossza alapján tesznek különbséget az egyes hálózati struktúrák között, amelyhez két szélsőséges (ideáltipikus) struktúrát vesznek alapul.¹¹ Az egyik ilyen struktúra a már ismertetett véletlen hálózat, ahol a lokális kapcsolatok nem jelentősek, ellenben az elérési utak rövidek. A másik szélsőséges struktúra a szabályos hálózat. Egy szabályos hálózatban a csomópontok csak lokális kapcsolatokkal rendelkeznek, ami magas klaszterezettséget, ugyanakkor hosszú elérési utakat eredményez. A két

¹¹A klaszterezettségi együttható a lokális kapcsolatok szerepét méri a hálózatban: az egyes csomópontokra számított lokális klaszterezettségi mutatók átlagaként adódik, mely utóbbiak egy-egy csomópont környezetének integráltságát mérik. Az átlagos elérési úthossz azt mutatja meg, hogy a hálózat csomópontjai átlagosan milyen messze található egymástól a hálózatban: az egyes csomópont-párok közötti legrövidebb utak átlagaként kapjuk meg. A két mutatóról részletesebb módszertani leírás található a 3.4.1. szakaszban.

szélsőséges struktúra között a csomópontok közötti kapcsolatok áthelyezése teremt kapcsolatot. Egy szabályos hálózatból kiindulva, minél nagyobb valószínűséggel helyezzük át a kapcsolatokat, annál közelebb kerülünk a véletlen hálózatokhoz. Ebben a modellben megmutatható, hogy elegendő csupán viszonylag kis számú kapcsolat véletlenszerű áthelyezése ahhoz, hogy a lokális struktúrák dominanciája mellett az átlagos elérési úthossz a véletlen hálózatokra jellemző értékre csökkenjen, ezáltal a kis világ struktúra kialakuljon. A dolgozat további részeiben a Watts-Strogatz modellre jelentősen építünk, így annak részletesebb módszertani kifejtését is megteszem az arra alkalmas helyen.

Akárcsak a véletlen hálózatok, a kis világok is leírhatók egy reprezentatív csomóponttal, vagyis egy átlagos fokszámmal. Barabási (2002) azonban azt emeli ki, hogy a valós hálózatok nem jellemezhetők reprezentatív szereplővel: néhány csomópont rendkívül nagy számú kapcsolattal rendelkezik, míg a csomópontok többsége kevés kapcsolattal bír. Az átlagos fokszám ugyan megadható, azonban a hálózat struktúráját elsősorban a nagyszámú kapcsolattal rendelkező, extrémális elemek határozzák meg: egy-egy ilyen csomópont kiesése adott esetben a hálózat széteséséhez vezethet. Ezt a speciális struktúrát skálafüggetlen hálózatnak nevezik, amely elnevezés abból fakad, hogy ezek a hálózatok nem írhatók le egy átlagos fokszámmal (reprezentatív szereplővel), vagyis a fokszám-eloszlásnak nincsen egy jól meghatározható átlaga, skálája. (Itt jegyeznénk meg, hogy az angol terminológiában használt *scalefree* kifejezés, valamint az alapjául szolgáló *scale* szó nem csupán a magyar skála kifejezés megfelelője, hanem jelent még adott, valamilyen skálához viszonyított méretet is. A szónak ez az értelme világít rá a legjobban a kifejezés eredetére.) Barabási és társai azt a fontos felismerést mutatták be, hogy a valóságban előforduló hálózatok nagy része ilyen skálafüggetlen tulajdonságot mutat (közlekedési hálózatok, társadalmi kapcsolatháló, publikációs hálózatok, kristályszerkezetek, fehérje-hálózatok, stb.) (Barabási és Albert, 1999; Barabási és szerzőtársai, 2000; Barabási, 2003). A 2.2. ábrán látható egy tipikus skálafüggetlen struktúra: néhány központi szereplő dominanciája mellett a periférikus csomópontok közötti átkötések nem jellemzőek.

Barabási és Albert (1999) egy egyszerű modellt is felvázolnak, amely a skálafüggetlenség kialakulását magyarázza. Modelljüknek a preferenciális kapcsolódás nevet adják, melynek lényege, hogy egy növekvő hálózatban az új csomópontok egy egyszerű szabály szerint alakítják ki új kapcsolataikat: nagyobb valószínűséggel kapcsolódnak olyan csomópontokhoz, ami magasabb fokszámmal rendelkezik. Így néhány csomópont rendkívül központi szerepet fog betölteni, míg a többség kevesebb kapcsolattal fog rendelkezni. A modellben alkalmazott fejlődő hálózati hipotézis ugyanakkor azt is eredményezi, hogy az „idősebb” csomópontoknak logikusan több kapcsolatuk lesz, hiszen több idejük van a kapcsolatok felhalmozására. Amennyiben nem vezetünk be további „vonzásági” paramétereket, úgy a központi elemek egyben az idősebb elemek lesznek.



2.2. ábra. Tipikus skálafüggetlen hálózati struktúra

2.3.2. Hálózati társadalom és az új gazdaság

A hálózatok és a hálózati társadalom jelenségét speciális, a disszertáció szempontjából lényeges szemszögből tárgyalja Castells (2000). Meglátása szerint a huszadik második felében egy új, a korábbiaktól lényegesen eltérő jellemzőkkel és mozgástörvényekkel rendelkező gazdasági és társadalmi struktúra bontakozott ki, amely a gazdasági és társadalmi fejlődést a következő időszakban alapvetően meghatározza. Ezt az új struktúrát/kort az információ korának nevezi és alapvetően az információs technológiák megjelenésével és elterjedésével hozza összefüggésbe.

Nagyon lényeges elem ebben a gondolatmenetben, hogy az információ új kora sem szakít véglegesen a gazdaság és a társadalom szerveződésének alapvető elveivel: ami megváltozott, az nem az emberiség által végzett tevékenységek köre, hanem az, hogy egy olyan technológiai képesség alakult ki, amellyel közvetlen termelőerőként lehet felhasználni azt, ami az embereket a többi fajtól alapvetően megkülönbözteti: nevezetesen kiemelkedő szimbólum-feldolgozó képességét. Az új technológia magát az információra hat, azt formálja, alakítja, míg korábban a helyzet inkább fordított volt: az információ határozta meg a technológiát.

Az új viszonyok alapvetően hálózati jellegűek, amelyeket a globalizáció fog össze. Először is az integrált pénzügyi piacok, a globális tőkeáramlás képezi az egyik legfontosabb glo-

balizációs erőt, amely mellett a piacok, az áru- és szolgáltatás-kereskedelem globalizációja is mind szélesebb körű. Ebben a globális pénzügyi és kereskedelmi térben multinacionális vállalatok hálózata képezi a szerveződés magját, amelyek egy globális hálózat csomópontjaiként kis és közepes vállalatok lokális klasztereinek központját alkotják. Ugyanakkor maguk a multinacionális vállalatok is egyre decentralizáltabb módon szervezettek, egymáshoz szorosabban vagy kevésbé szorosan kapcsolódó szervezeti egységek hálózataként jeleníthetők meg, így adva flexibilitást a szervezetnek. A kereskedelmi és pénzügyi kapcsolatok mellett a kutatás-fejlesztés, vagyis a technológia is fontos összekötő elem. A fejlesztés költségeinek növekedésével és az innováció egyre fontosabbá válásával párhuzamosan a nagyvállalatok rákényszerülnek arra, hogy stratégiai szövetségek keretében tudást és információt osszanak meg egymással, ami azonban a globális tudás- és technológia transzfer felgyorsulásához vezet.

Az új kor kialakulása azonban nagyon szorosan összefügg az információs technológia kialakulásával, amely az 1960-as és 70-es évektől kezdődően vált egyre meghatározóbb technológiai paradigmává. Sem a pénzügyi piacok, sem a kereskedelem, sem pedig a nemzetek közötti üzleti együttműködések nem válhattak volna globálissá, ha nem alakul ki az a technológiai infrastruktúra, amely az információk globális méretű kezelését és a sokszor földrészek közötti kommunikációt lehetővé teszi vagy megkönnyíti. Ugyanakkor azt is látni kell, hogy a technológiai infrastruktúra és a hálózati gazdaság és társadalom kialakulása nem egyszerű lineáris folyamat, hanem a két faktor kölcsönös, egymást erősítő elemként jelenik meg. A globális tranzakciókat és kommunikációt lehetővé tevő technológia a maga hálózati topológiájával bizonyos szinten meghatározza a technológiai eszközök mentén kialakuló szervezeti, intézményi és társadalmi szerveződési formákat. Jól példázza ezt a folyamatot az információs korszak bölcsőjeként és egyben máig meghatározó szellemi és térbeli referenciapontjaként tekintett Szilícium Völgy története. A terület prosperitását néhány kormányzati projektnek és az általuk teremtett piacnak köszönheti, azonban hamar önálló, dinamikus motorjává vált az információs technológiák fejlődésének, amihez nagyrészt a technológiai kreativitás kultúrája és a gyors személyi sikerek szerepmódelje is hozzájárul a kezdeti kormányzati impulzusok mellett. A dinamikus és kreatív légkör vállalatok és magasan képzett szakemberek tömegét vonzotta a térségbe, ami egyben azt is jelentette, hogy ezek a mozgások kapcsolatokat hoztak létre e cégek és egyének származási országa, régiója, valamint a technológiai centrum között. Ezek a hálózatok aztán alapvetően meghatározták a fejlődő régiók (India, Kína, Izrael) lehetőségeit abban, hogy az új technológiákhoz és értékes üzleti információkhoz hozzáférjenek. (Lásd pl. Saxenian 1994, 1999.)

A tőke globalizálódása mellett azonban a munkaerő, mint a termelés másik jelentős erőforrása, alapvetően lokális marad. Mindazonáltal a hálózati átalakulás a munkát sem hagyja változatlanul: az információs technológia fejlődése a munkaszervezés új módjait teszi lehetővé, amely egyrészt a munkaerő hagyományos, kollektív szerveződését megbontja azáltal, hogy egyéni, vagy ha úgy tetszik csomóponti szintre bontja a munkafolyamatokat, másrészt pedig alapvetően áthelyezi a munkafolyamatok súlypontjait a globális hálózatokban. Ezek a változások a tőke és a munka közötti kapcsolatokat és feszültségeket egy olyan új struk-

túrába helyezik, ahol a fő kérdéssé már sokkal inkább a tőkeáramlás hideg logikája és az emberek kulturális értékei közötti ellentmondások válnak.

A hálózati társadalom tehát hálózatok hálózataiként jelenik meg, ahol a csomópontok és az azokat összekötő kapcsolatok is rendkívül sok dimenzióban jelenhetnek meg, azonban az egyes dimenziók között pontosan ezek a hálózati kapcsolatok biztosítanak lényeges átjárási pontokat. A gazdaság és a társadalom szerveződésének azonban lényeges eleme az információ és a tudás áramlása, tehát azok a kapcsolatok, amelyek alapvetően az innováció, az új ismeretek, a technológiai tudás átadására szolgálnak és jönnek létre. Ahogy az itt elmondottakból is látszik, a jelenlegi gazdasági és társadalmi folyamatok alapvetően az információ áramlását biztosító materiális és immateriális hálózatok szerepét emelik ki, így ezek a hálózati struktúrák kiemelt fontosságúak. A disszertáció alapvető fókuszusa e tudáshálózatok vizsgálata, a következő szakasz már erre a kérdéskörre fókuszál. Fontos azonban azt is látni, hogy a tudáshálózatok dinamikája és működése nem független a gazdasági és társadalmi viszonyok más dimenzióitól. Az elkülönült vizsgált konkrét megértési célokat szolgál, azonban a gazdaság-társadalmi rendszer egészét célzó megértési folyamat más viszonyrendszerek integrált kezelését is igényli.

2.3.3. Tudáshálózatok vizsgálata

Ahogy a 2.2. alfejezet végén kiemeltük, a tudás diffúziója során, vagyis abban a folyamatban, amely a gazdaság lokális pontjain keletkező új tudást végül az egész gazdaság számára hozzáférhetővé teszi, kiemelkedő szerepe van a gazdasági szereplők (munkavállalók, vállalatok, egyetemek, stb.) közötti kapcsolatoknak, illetve e kapcsolatok hálózatának. Ezek a hálózatok jelentik azt a rendszert, amelyen keresztül a tudás a gazdasági szereplők között áramlik. Ennek megfelelően a tudáshálózatokat úgy foghatjuk fel, mint e tudás-áramlás fontos médiumát: olyan formális és informális kapcsolatok összességét, amelyek a gazdaság különböző szereplői között jönnek létre, legyenek ezek egyének, vállalatok, egyetemek, állami intézmények vagy akár régiók mely utóbbi esetben a hálózat egy csomópontja az előbbi szereplők egész csoportját jelenti. Ezek a kapcsolatok, mint például munkaszerződések, baráti kapcsolatok, közös publikációk vagy K+F projektek ebből a szempontból mind olyan kapcsolatoknak tekinthetők, amelyek hozzájárulnak a tudás terjedéséhez a gazdaságban. A disszertációban a tudáshálózatok fogalmát ebben az értelemben használom, bár különböző dimenziókban. Az elméleti részekben (3. és 4. fejezetek) vállalatok közötti kapcsolatok jelennek meg, bár e kapcsolatok konkrét tartalma az elméleti megközelítés okán nem releváns. Az empirikus részben (5., 6. és 7. fejezetek) a hálózati csomópontok európai régiók lesznek, miközben tartalmukat tekintve a kapcsolatok szabadalmi feltalálói együttműködések reprezentálnak, kiemelve egy lehetséges kapcsolati formát és természetesen eltekintve számos egyéb lehetséges elemről, amely a régiók között tudás-transzferet tesz lehetővé.

Az alábbiakban a tudáshálózatokkal kapcsolatos elméleti és empirikus szakirodalom rövid áttekintését adjuk. A két irányvonal elkülönült tárgyalására a megfelelő strukturáltság

mellett azért is szükség van, mert a disszertáció mindkét megközelítés eredményeire épít, azokat integrálja.

2.3.3.1. Elméleti modellek

Cowan és Jonard (2004) kiemelik, hogy a közgazdaságtanban kevés figyelmet kap az a mód, ahogy az információ terjedése a piacok működésére hat. Bár az ár lényeges szempont, az információ terjedését a piaci működés mögött rejlő kommunikációs struktúrák és hálózatok határozzák meg. E kapcsolatok jellege azonban hatással van a kommunikációs csatornákon keresztül továbbadott információ jellegére, mennyiségére és magára a kommunikáció hatékonyságára, ami pedig a modellezett rendszer egészének működésére, vagyis az aggregált szinten megfigyelhető jelenségekre is kihatással lehet. Két fontos kérdés merül fel ebben az esetben. Egyrészt, hogy amennyiben a hálózati struktúra exogén adottság, miként befolyásolja ez a struktúra a rendszer outputját. Másrészt, ha a hálózat kialakulása endogén, akkor milyen hálózati struktúra jön létre?

Az első kérdésre adott válaszok elsősorban a technológiai diffúzió irodalmában jelennek meg. Mint arra korábban kitértünk, a technológiai diffúzió elméletei mikro- és makroszinten vizsgálják a tudás (technológia) terjedését. A makroszintű elméletek eleinte a diffúzió időbeli lefutását vizsgálták és nem fordítottak különösebb figyelmet arra, hogy az információ és a tudás milyen struktúrákon (hálózatokon) keresztül terjed.

Abrahamson és Rosenkopf (1997) az elsők között vetik fel, hogy az a tény, hogy a diffúzió társadalmi hálózatokon keresztül valósul meg, e hálózat egyedi jellemzői fontos tényezővé lépnek elő a diffúziós folyamatban. Tanulmányuk elsősorban azt vizsgálja, hogy milyen okok húzódnak meg azon jelenség mögött, hogy az információk és innovációk nem minden esetben terjednek el teljesen a gazdaság szereplői között, miként azt a diffúziós modellek korai családja implicite feltételezi. Modelljükben a hálózati struktúra speciális belső határainak korlátozó szerepét emelik ki. Egy egyszerű centrum-periféria viszonyokat tükröző hálózati struktúrát alkalmazva arra a következtetésre jutnak, hogy a centrumon kívüli kapcsolatok sűrűségének a növekedése az újítást adaptáló végző arányának növekedéséhez vezet.

Cowan és Jonard (2005) a tudás diffúziójának két mikroökonómiai modelljét vizsgálják. Mindkét modell esetén egy előre adott hálózati struktúrának a diffúzió hatékonyságára gyakorolt hatását vizsgálják. A két modell abban különbözik egymástól, hogy a tudás terjedésének módja más. Az egyik modell az ún. tudás-barter elvén alapul, amikor a hálózati partnerek egy esetleges együttműködés alkalmával mintegy „kicserélik” egymással tudás-elemeiket. Ez tulajdonképpen az egymástól való kölcsönös tanulás esete. A másik modell a tudás „sugárzásának” nevezhető (knowledge broadcast), ahol a megszerzett információt a hálózat tagjai „szétsugározzák” a szomszédos csomópontok felé, akik adott abszorpciós paraméter mellett beépítik ezt a tudást saját tudásbázisukba. Mindkét modell esetén az derül ki, hogy a kis világokra jellemző hálózati struktúra adja a legkedvezőbb eredményt a tudás-diffúzió szempontjából. Ez azt jelenti, hogy azon hálózati struktúrák a leghatéko-

nyabbak a tudás terjedése szempontjából, amelyek egyszerre mutatják a rövid elérési utak és a magas szintű lokális klaszterezettség jellemzőit.

Az iménti modellek olyan szituációkat vizsgálnak, ahol a hálózati struktúra rögzített, és a strukturális jellemzőknek a rendszer outputjára, működésére gyakorolt hatását vizsgáljuk.¹² A Cowan és Jonard (2004) által felvetett másik kérdésre, nevezetesen, hogy milyen hálózati struktúrák alakulnak ki, ha a modell szereplői dönthetnek a kapcsolatok kialakításáról és azok nem exogének, az alább kiemelt néhány meghatározó tanulmány kísérel meg választ adni.

Jackson és Wolinsky (1996) elsősorban a hatékonyság és a stabilitás kapcsolatát vizsgálják endogén módon alakuló hálózatokban. A modell központi eleme az a mód, ahogyan az egyes csomópontok a hálózati kapcsolatok kialakításából profitálnak: egy csomópont hozzáfér mindazon csomópontok információjához (tudásához), amelyekkel közvetlenül vagy közvetve kapcsolatban áll, a hálózatban mért távolság függvényében azonban csökken az egy csomóponttól érkező információ értéke. Hatékonynak neveznek egy hálózatot, ha az az adott paraméterek mellett a lehető legjobb outputot eredményezi, azaz az egyes csomópontok belső értékeinek (hasznosságainak, tudásának) értéke maximális. Stabil egy hálózat, ha egyetlen csomópont sem motivált arra, hogy új kapcsolatokat alakítson ki, vagy létező kapcsolatokat szüntessen meg. Eredményeik azt mutatják, hogy a modell paramétereinek különböző értéke mellett eltérő hálózati struktúrák adódnak hatékony struktúraként. Amennyiben a kapcsolatok fenntartásának költsége relatíve kicsi, úgy a teljes hálózat mutatja a legnagyobb hatékonyságot.¹³ A költségek közepes szintjei mellett a csillag-struktúra (tulajdonképpen egy szélsőségesen skálafüggetlen hálózat) a leghatékonyabb, amely mindenkit magában foglal, egy központi szereplővel. A költségek relatíve magasabb értékei mellett a leghatékonyabb struktúra az üres hálózat.¹⁴ Stabilitás szempontjából azonban a fenti összefüggések már nem érvényesek, így a tanulmány egy fontos konklúziót fogalmaz meg: a hatékony és stabil struktúrák között bizonyos feszültség fedezhető fel: a hatékony hálózati struktúrák nem feltétlenül stabilak is.

Az előbbihez hasonló modell játékelméleti közelítését adja Bala és Goyal (2000). E megközelítés szerint a hálózat tagjainak kapcsolati döntéseit egyfajta stratégiaként fogjuk fel. Így egy adott stratégia tulajdonképpen egy kapcsolati vektort jelent, amely azt mutatja meg, hogy az egyes csomópontok mely további csomópontokkal létesítenek kapcsolatot. Modelljünkben a hálózati kapcsolatok endogenizálásának módja az, hogy egy adott kezdeti hálózati struktúrából (stratégia-profilból) kiindulva a játék iterációkon keresztül halad előre. Minden iterációban valamennyi csomópont adott valószínűséggel marad a korábbi stratégiájánál és komplementer valószínűséggel megváltoztatja azt, mégpedig a megelőző

¹²Ez az irányzat elsősorban Robin Cowan és Nicholas Jonard munkái nyomán vált szerves részévé az innováció gazdaságtanával foglalkozó szakirodalomnak.

¹³A kapcsolatok fenntartásának költségét az ún. spillover paraméter értékéhez viszonyítjuk: milyen költsége van egy kapcsolat fenntartásának ahhoz viszonyítva, amennyi veszteség keletkezik az információ egy kapcsolaton keresztül történő transzferálása közben. Így logikus, ha ezek a költségek a magas spillover-értékek miatt elhanyagolhatóak, úgy a legtöbb kapcsolat létrehozása optimális.

¹⁴Ebben az esetben a magas költségek miatt nem érdemes kapcsolatokat létrehozni, mivel azokat nem kompenzálja a kapcsolatokon keresztül elérhető külső tudás (spillover).

iteráció hálózati struktúrájára (vagyis a stratégia-profilra) adott legjobb válasz stratégia formájában. Eredményeik azt mutatják, hogy viszonylag hamar (mindössze 9-11 iteráció után) kialakul a szigorú Nash-egyensúly, ahol a hálózat vagy üres, vagy kör-hálózat (szabályos hálózat, egyirányú kapcsolatok esetén), vagy pedig csillag-struktúra (skálafüggetlen hálózat, kétirányú kapcsolatok esetén) alakul ki.

Cowan és szerzőtársai (2006) a tudás szofisztikáltabb megközelítése mellett a tudás-felhalmozás és a hálózatok kialakulásának összefüggéseit vizsgálják. A szofisztikáltabb megközelítés alatt azt értjük, hogy az eddig bemutatott modellek egydimenziós tudás-felfogásával szemben a tudást két dimenzió mellett értelmezik: technológiai területek adóttak, amely területeken a vállalatok különböző (akár zérus) szintű (mélységű) tudással rendelkeznek. Ily módon a szereplők tudását egyetlen valós szám helyett egy valós vektor reprezentálja. Modelljük elsősorban nem a kialakuló hálózati struktúra formájára keresi a választ, hanem a tudásbázisok viszonyának hatását a hálózati kapcsolatok kialakulására. A modell két vezérlő ereje egyrészt a kapcsolatok bizalom-építő szerepe, amely a közös innovációs tevékenység (várható) hatékonyságát növeli az együttműködés eredményessége kockázatának csökkentésével, másrészt pedig a kapcsolatok azon hatása, hogy az együttműködés a tudásbázisok közelítése révén a közös innováció (várható) hatékonyságát csökkenti.

Sebestyén (2010) hasonló, stratégiai kapcsolat-kialakításon alapuló modellt mutat be, amellyel a sokféleség szerepét vizsgálja az innovációs folyamatban. A kapott eredmények arra mutatnak, hogy a tudás-tér (amely a vállalatok vizsgált csoportját jellemzi) kezdeti jellemzői befolyásolják mind a vállalatok tudásának, mind pedig a hálózati struktúrájának az evolúcióját. Általánosságban az látszik, hogy a vállalatok zárt, tehát külső sokkokkal nem befolyásolt hálózatában a kölcsönös interakciókon keresztül történő tudás-csere a sokféleség csökkenéséhez vezet. Ez azonban nem minden esetben párosul az innovativitás csökkenésével: található olyan szituáció, amelyben a hálózat növekvő innovációs aktivitást mutat, annak ellenére, hogy a tudásbázisok homogénné válnak. Ez az eredmény a korábban a spilloverek kapcsán említett két agglomerációs extern hatással is összhangban áll, és arra mutat rá, hogy a kiindulási tudás-bázis jellemzőitől függően (amely alatt tulajdonképpen a sokféleség kezdeti értékét értjük) egyik vagy másik extern hatás dominálja az evolúciós folyamatokat.

Carayol és Roux (2006) egy olyan modellt mutatnak be, amely a hálózat dinamikus formálódása mellett térbeli vonásokat is tartalmaz. Ez azért fontos, mert az eddig tárgyalt modellek a térbeliséget mellőzték a vizsgálatból: a távolság fogalma csak a hálózaton belüli, ún. geodetikus távolságként volt értelmezhető. Ilyen értelemben a tér egydimenziós. Ebben a modellben azonban a hétköznapi fogalmaink szerinti térbeliség is szerepet kap, amennyiben a hálózat tagjait nem csupán azok kapcsolati struktúrája jellemzi, hanem térbeli pozíciójuk is. A modellben alkalmazott tér csupán egydimenziós (a hálózat tagjai egy körvonalon helyezkednek el), a kapott eredmények azonban így is fontos tanulságokkal szolgálnak. Legfontosabb eredményük, hogy megmutatják, hogy a tudás transzferálható-

ságának nagy közbülső tartományokban kis világok alakulnak ki, rövid elérési utakkal és magas klaszterezettséggel. Így sikerül gazdasági, költség-haszon megfontolásokon alapuló magyarázatot adni arra a jelenségre, hogy a hálózati kapcsolatok jellemzően lokálisan alakulnak és így a tudás-áramlás is lokális. A kis világok hipotézise mellett a skálafüggetlenséget is vizsgálják, e téren azonban az eredményeik kevésbé markánsak. A kapott fokszám-eloszlás ugyanis inkább a (nem-skálafüggetlen hálózatok esetén jellemző) Poisson-eloszlás egy torzabb, jelentősebb ferdeséget mutató változata, de egyértelműen meghatározható az eloszlás módusza, így a skálafüggetlenség nem teljes mértékben magyarázható meg a modell segítségével.

A fenti összefoglalásból látható, hogy a hálózatok modellezése egyre szélesebb teret nyer az innovációval foglalkozó irodalomban: a módszer segítségével egyre több jelenséget vizsgálnak, és egyre több jelenséget sikerül megmagyarázni. Ugyanakkor az is fontos, hogy a modellek jellemzően parciális modellek, azaz kifejezetten a tudás vagy információ hálózaton belüli terjedésére fókuszálnak. Disszertációmban alapvetően ezt a modellezési irányvonalat követem, de igyekszem egy szélesebb kontextusba ágyazni a hálózati modellezés módszertanát, amennyiben egy általános egyensúlyi modellbe építem be a tudáshálózatok szerepét. Ez a lépés azért nagyon fontos, mert így a tudáshálózatok modellezésétől továbblépünk a gazdasági növekedést magyarázó modellek felé, amelyek azonban mindeddig nem tartalmaztak explicit hálózati dimenziót. Annak érdekében viszont, hogy a tárgyalás kezelhető keretek között maradjon, ésszerű kompromisszumokat kell kötni. Éppen ezért a hálózati modellezés terén elindult, eddig kifejtett két irányvonalból csupán az elsőt integrálom, vagyis az exogén hálózati struktúra mellett adódó következtetéseket vizsgálom, és nem foglalkozom a hálózati kapcsolatok alakulásának dinamikájával. Ez természetesen lényeges megkötéseket is jelent a tárgyalásra nézve, ugyanakkor fontos kiemelni azt, hogy a hálózati dinamika beépítése a modellbe az imént ismertetett modellezési elvek alapján nyilvánvaló továbblépési irányként jelentkezik a későbbiekben.

2.3.3.2. Empirikus vizsgálatok

A tudáshálózatok empirikus vizsgálata során az egyik legfontosabb újdonság, hogy olyan adatokkal kell dolgozni, amelyek a gazdasági szereplők közötti kapcsolatokat tükrözik és ez a típusú adatforrás nem része a közgazdászok és statisztikusok standard eszköztárának (Maggioni és Uberti, 2010). A kapcsolati adatok alapvetően két forrásból származhatnak. Az első ilyen forrás interjúkon, azaz a gazdasági szereplők közvetlen megkérdezésén alapul. A hálózatok feltérképezésének ez a módja az ún. hólabda effektuson alapul, amikor a hálózat egyik tagjától származó információk alapján jutunk el a többi szereplőhöz. Ezzel a módszerrel ún. ego-hálózatokat kapunk, azaz egy-egy szereplő köré épülő kapcsolatokat, amelyeket aztán aggregálhatunk egy egybefüggő hálózattá. (Lásd például: Giuliani és Bell, 2005; Morrison, 2008; Ter Wal és Boschma, 2009; Maggioni és Uberti, 2009).

Ebben az esetben a hiányzó adatok szerepe különösen fontos lehet: ha ugyanis egy kulcszereplő hiányzik a hálózatból, akkor az adatokon kiszámolt strukturális mutatók torz képet

adnak a hálózatról. Egy további probléma a hálózat fejlődésének vizsgálata. Megfelelően részletes interjúk kérdései többszöri lebonyolítása egyrészt nagyon költséges, másrészt pedig az adatgyűjtési nehézségek és egyéb okok (pl. csődök) miatt nem is biztos, hogy két különböző időpontban készült hálózati felmérés összehasonlítható egymással (Ter Wal és Boschma, 2009).

A kapcsolati adatok másik fontos forrása másodlagos adatokat jelent. Ebben az esetben már létező adatbázisokból következtetünk a hálózati kapcsolatokra. Az első ilyen típusú vizsgálatok kereskedelmi áramlásokat elemeznek (Dorogovtsev és Mendes, 2005; Garlaschelli és Loffredo, 2005), amelyek értelemszerűen a külkereskedelmi adatbázisokat (OECD, ENSZ, Eurostat, stb.) használják fel. Egy másik érdekes irányzat e szerint a módszertan szerint a vállalati igazgatósági tagok hálózatának vizsgálata.¹⁵

Ter Wal és Boschma (2009) azt hangsúlyozzák, hogy az innovációs irodalomban a szabadalmi adatbázisok képezhetnek olyan alapot, amelyre építve hálózati elemzést lehet végezni. A szabadalmak eredendően olyan adatok, amelyek egy egyén, egy szervezet vagy akár egy földrajzi egység innovációs tevékenységét, outputját mérik. Ebből a szempontból a hálózati adatok tulajdonképpen egyszerű attribúciós adatbázist alkotnak, azonban minden szabadalom értelmezhető egy relációs perspektívából is. Ez azt jelenti, hogy a szabadalmi adatbázisban megjelenő információk rálátást biztosítanak az innovációs folyamatban kialakuló, vagy az innováció alapját képező tudás-áramlások különböző hálózataira (Maggioni és Uberti, 2010).

Az első ilyen alkalmazások a már ismertett szabadalmi hivatkozásokat veszik alapul és ezek alapján alakítanak ki hálózatokat a különböző gazdasági egységek között. Verspagen (2005) az üzemanyagcella ágazatban vizsgálja a technológiai trajektóriákat szabadalmi hivatkozások segítségével. Módszerük arra épít, hogy a szabadalmi hivatkozások a fontos technológiai tudás útját és fejlődését mutatják meg szabadalomról szabadalomra, így segítségükkel nyomon követhető a technológiák alapvető pályája egy iparágon belül. A tanulmány eredményei azonban kevésbé a hálózati struktúrára vonatkoznak, mint inkább az üzemanyagcella iparág fő evolúciós pályájára. Li és szerzőtársai (2007) technológiai területek, szervezetek és országok közötti tudás transzfert vizsgálnak a nanotechnológiai iparágban. Elemzésük főként a hálózatok struktúrájára vonatkozik. Eredményeik megmutatják, hogy az iparágban az Egyesült Államok tekinthető egyfajta tudás-centrumnak, amennyiben a legtöbb hivatkozás ide irányul. A megfigyelt hálózati struktúrák alapján arra a következtetésre jutnak, hogy attól függően, hogy a hálózat csomópontjainak a szervezeteket, a technológiai területeket vagy az országokat tekintjük, a tudás-transzfer hatékonyságát illetően eltérő hatékonyságú hálózatokat kapunk. Ugyanakkor valamennyi hálózatot lokális hivatkozási klaszterek jellemeznek. Szabadalmi hivatkozási hálózatok elemzését mutatja be még ezen kívül Jaffe és Trajtenberg (2002), Gress (2010) vagy Ellis és szerzőtársai (1993).

¹⁵Ezzel a kérdéssel az ún egymást átfedő igazgatóságok (interlocking directorates) irodalma foglalkozik részletesen. Lásd pl. Davis és szerzőtársai (2003), Burris (2005).

A hivatkozások mellett egy további lehetőségként adódik az, hogy a szabadalmi kooperáció alapján képzünk hálózatot. Ekkor az egy szabadalomban együttműködő feltalálók vagy a szabadalmat benyújtók közötti kapcsolatok alapján állítunk össze egy kooperációs hálózatot, amely a szabadalom létrehozása közben a részt vevő szereplők között létrejövő tudástranszfert lehet képes nyomon követni. Fontos kiemelni, hogy amíg a hivatkozásokon alapuló megközelítés inkább a kodifikált tudás áramlását követi nyomon, addig a kooperációs hálózatok a tacit tudás áramlásának feltérképezésére alkalmasabbak. Ejeremo és Karlsson (2004) azt is hangsúlyozzák, hogy a szabadalmi együttműködések mind minőségileg, mind mennyiségileg meghatározóbb mércéjét jelentik a spillovereknek.

Cantner és Graf (2006) dinamikus szemléletben vizsgálják a jénai feltalálók hálózatát. Eredményeik szerint a városon belüli kapcsolatok egyre dominánsabbá válnak a vizsgált időszakban annak ellenére, hogy a külső szereplők száma nő. Ugyanakkor a hálózat fragmentáltsága idővel csökken, miközben a központi szereplők inkább formális, a periférikus szereplők pedig informális kapcsolatok kialakítására törekednek. Ejeremo és Karlsson (2004) vizsgálata térbeli dimenziót is alkalmaz. Nem feltalálók vagy vállalatok közötti hálózatokat vizsgál, hanem régiók közötti kooperációt: a kooperáció erőssége két régió között attól függ, hogy mennyi személyes együttműködés figyelhető meg a két régió között. Eredményeik azt mutatják, hogy a régiók közötti kapcsolatok erősségét a földrajzi távolság jelentősen befolyásolja, ugyanakkor lényeges különbség fedezhető fel az egyes technológiai területek között. Maggioni és Uberti (2006) öt európai ország régiói közötti szabadalmi hálózatokat vizsgálnak. Eredményeik szerint a szabadalmi hálózatok – kevés számú nemzetközi kapcsolattól eltekintve – elsősorban országokon belüli kapcsolatokat jelentenek. Gravitációs modellt alkalmazva azt mutatják meg, hogy a régiók közötti földrajzi távolság lényeges szempont a tudás-áramlás szempontjából. Arra a következtetésre jutnak, hogy a fejlődő és a fejlett régiók közötti jövedelmi konvergenciát a hálózati dinamika hátráltatja, amennyiben a különböző tudományos-technológiai karakterű régiók közötti tudás-áramlás a nagy technológiai távolság miatt nehezebb.

Hasonló adatbázist mutat be és alkalmaz például Parag és Sebestyén (2009), illetve Sebestyén és Parag (2010) európai NUTS2 régiókra felírva. Ezekben a vizsgálatokban a hálózatok aggregált struktúrája és a kapcsolatok dinamikája áll a középpontban. A struktúrát tekintve kimutatható, hogy a skálafüggetlenség valamint a kis világok jellemzői dominálják ezeket a hálózatokat, ugyanakkor a hálózatokfejlődésének dinamikájában a térbeli közelség szerepe egyértelműen kimutatható. E két tanulmányban alkalmazott adatbázist használok a disszertáció 5. fejezetében bemutatásra kerülő empirikus vizsgálatban, illetve a 7. fejezet szimulációs modelljében. Az adatbázis és a módszertan részletes leírására ennek megfelelően később kerül sor.

A szabadalmak feltalálói közötti kapcsolatok elemzése mellett logikusan adódik az a lehetőség, hogy a feltalálók és a tudást alkalmazók, vagyis a szabadalmak tulajdonosai közötti kapcsolatokat vizsgáljuk. Breschi és Lissoni (2003) a szabadalmi feltalálók különböző vállalatok (szabadalom-tulajdonosok) közötti mobilitása alapján alkot vállalatok közötti há-

lőzatokat. Elsősorban arra keresik a választ, hogy a feltalálók mobilitásának figyelembe vétele a tudás-áramlásban mennyiben befolyásolja a szabadalmi hivatkozások magyarázó erejét a tudás-transzfer lokalitása szempontjából. Eredményeik arra mutatnak, hogy a tudás elsősorban a feltalálók és a bennük megtestesülő tudás mobilitása révén terjed, így a tudás-spilloverek annyiban lokálisak, amennyiben a feltalálók mobilitása is lokális. Maggioni és szerzőtársai (2008) egy további módszert alkalmaznak, amelyben olasz régiókat vizsgálnak és egy szabadalom esetén megkülönböztetik a feltalálók régióit a felhasználók (szabadalom-tulajdonosok) régióitól. Így a tudás termelése (feltalálók) és alkalmazása (felhasználók, tulajdonosok) elválik egymástól és vizsgálhatóvá válik az innovációs folyamat iránya regionális szempontból: mely régiók azok, ahol a tudás tipikusan megjelenik, és mely régiókban kerül felhasználásra végül az új tudás.

Jól látható az eddigiek alapján, hogy a tudáshálózatok kutatása szorosan összefonódik a térbeliség kérdésével is. Ez az összefüggés logikusan következik is mindabból, amit a tudás-spilloverek kapcsán korábban elmondtunk. Másrészt az is látszik, hogy bár a tudáshálózatok kutatása egyre fontosabb részévé válik az innovációval foglalkozó szakirodalomnak, még igen sok feltáratlan terület adódik, különös tekintettel a hálózati struktúra és a hálózatokra épülő rendszerek aggregált teljesítményének kapcsolatára. A disszertáció ebben az irányban kísérel meg egy óvatos lépést tenni, összehangoltan az előző alpont végén megfogalmazott módszertani célokkal, mintegy azok empirikus háttereként.

2.4. A disszertáció tézisei és felépítése

2.4.1. Tézisek

Az előbbi oldalakon a gazdasági növekedéssel kapcsolatos közgazdasági gondolkodás egy nagy ívű pályáját mutattam be, amely a tudás szerepének felismerésétől jut el a lokalitás és a kapcsolati hálók szerepének vizsgálatához. Az első lépés ebben a gondolati láncban a tulajdonképpen az a felismerés, hogy a fejlett gazdaságok (anyagi értelemben vett) jóléti szintje tulajdonképpen a korábbi évszázadokban felhalmozott, elsősorban technikai jellegű tudásnak köszönhetően volt elérhető. Ez a tudás testesül meg a termeléshez felhasznált tőkejavakban, az emberi tudásban, a termelési eljárásokban, egyszóval mindabban, amit átfogóan technológiának nevezhetünk.

A tudás szerepe természetesen felveti a tudás létrejöttének, az innovációnak és a tudás elterjedésének, diffúziójának a kérdését: miként jut el a gazdaság és társadalom egy pontján felfedezett új ismeret a gazdaság és a társadalom többi szereplőjéhez, miként lesz az egyedi szereplő profittermelő képességét növelő innovációból az egész rendszer számára hozzáférhető, felhasználható tudás, technológia. A tudás terjedésének szerepét vizsgáló tanulmányok két fontos mozzanat körül látszanak kikristályosodni. Az egyik ilyen pont a térbeliség szerepe. Úgy tűnik, hogy a tudás (ésszerű időbeli korlátokat figyelembe véve) lokálisan terjed, ami a létrejövő új tudás jellemzőiből, nevezetesen annak tacit jellegéből

következik. Ugyanakkor a lokalitás szerepe időben, ágazonként eltérő lehet, ami felveti a tudás áramlása konkrét formáinak kérdését, ez pedig a második fontos pont. A tudás tacit elemeinek terjedésében a személyes kapcsolatok lényeges szerepet töltenek be. Ez egyrészt a tudás direkt átadása miatt van így, másrészt pedig a kölcsönös bizalom játszik fontos szerepet ennél a típusú tudás-transzfernél, ami szintén (gyakori) személyes kontaktus igényel. Ebben az esetben viszont a társadalmi kapcsolatok és azok hálózata alapvetően fontos terepévé válik a tudás áramlásának és így a gazdasági növekedés akár lokális, akár makroszintű elemzésének is.

A hálózatok elemzése azonban nem az innovációval és a lokális gazdasági fejlődéssel kapcsolatos szakirodalomban jelent meg először, hanem elsősorban szociológiai és fizikai tanulmányokban. Az innováció irodalmába ezekről a területekről terjedt át a hálózatokat vizsgáló módszertan. Elsősorban a matematikai és a fizikai szakirodalom foglalkozott a hálózati struktúrák szerepével (Watts és Strogatz, Barabási-Albert), rámutatva, hogy a hálózatok felépítésének jelentős szerepe van a hálózat aggregált szintű működése szempontjából. Ezek a gondolatok jelentek meg később az innovációval és a tudás-áramlással kapcsolatos hálózati modellekben. Ezek a modellek azonban, ahogyan azt be is mutattuk, elsősorban parciális modellek, így egy fontos lépés hiányzik ahhoz a körfolyamathoz, amely a gazdasági növekedés alapvető kérdéseitől a hálózatokon és a lokalitáson át visszatér a gazdasági növekedés kérdéséhez.

A disszertáció modellezési szempontból tulajdonképpen ebben az irányban vállalkozik egy óvatos lépés megtételére, amennyiben a hálózati struktúra szerepét és a tudás-áramlás hálózatokon keresztül történő modellezését explicit módon beépíti egy egyszerű általános egyensúlyi modellbe. A növekedési kérdések alapvető tárgyalásához természetesen e modellezési keret továbbfejlesztése szükséges, jelen dolgozatban elsősorban a lehetőségek felvetésére van mód és egy olyan modellt mutatok be, amely alkalmas a hálózati struktúrák és a makrogazdasági működés integrált kezelésére.

Az előző bekezdések alapján néhány alapvető tézis fogalmazható meg a vizsgált problémakör vonatkozásában és e tézisek alapján deriválhatóak azok a kérdések, amelyek megválaszolására e disszertáció keretében teszek kísérletet.

1. Tézis – A tudás és annak felhalmozása rendkívül fontos tényező a gazdasági növekedés szemszögéből. Ugyanakkor a gazdaság egyedi pontjain megjelenő tudás externális (növekedéshez vezető) hatásainak kialakulását a tudás diffúziója teszi lehetővé, amihez viszont a gazdasági szereplők közötti kapcsolatháló járulnak hozzá.
2. Tézis – A hálózatokat vizsgálva kiderül, hogy e hálózatok struktúrája lényeges szempontja a hálózatok elemzésének, továbbá a struktúrának fontos szerepe van a hálózatra épülő rendszer egésze működésének (outputjának, hatékonyságának) meghatározásában.
3. Tézis – Empirikus tesztek a személyes kapcsolatháló relevanciáját kimutatják az innovációs folyamatokban. Ezek a tesztek azonban parciálisak: adott régiók iparágak,

szűkebb minták alapján készültek, másrészt viszont a hálózati struktúrák globális szerepének elemzéséig egyelőre nem jutottak el.

A fenti három tézis alapján a következő kérdések fogalmazhatóak meg.

- Az 1. és 2. tézis kölcsönösen felveti azt a kérdést, hogy egy gazdasági rendszer modelljébe milyen módon építhető be a tudáshálózatok struktúrájának szerepe, egészen pontosan azon hálózatoké, amelyek az egyes gazdasági egységek (vállalatok, egyének, egyetemek, kutatóhelyek, stb.) közötti információ-, tudás- és technológia-áramlást lehetővé teszik, vagy adott esetben katalizálják.
- Az előző kérdés folyamánként (továbbra is az 1. és 2. tézis alapján) az a kérdés is felmerül, hogy a tudáshálózatok – és e hálózatok struktúrájának – explicit integrálása a gazdasági működést magyarázó modellekbe milyen eredményekre vezet, azaz kimutatható-e a strukturális jellemzők makroszintű outputra gyakorolt hatása, és ha igen, milyen új tapasztalatokkal szolgál ez a hálózatok parciális modelljeihez képest.
- A 3. tézis kapcsán merül fel az empiria kérdése, összekapcsolódva az előző kérdéssel: a tudáshálózatok struktúrája és a gazdaság makroszintű teljesítménye közötti kapcsolat empirikusan kimutatható-e.
- Az empirikus és elméleti megfontolások mellett felmerül az a kérdés is, hogy a tudáshálózatok kapcsolati struktúrájának explicit modellezése hasznos információkat képes-e nyújtani a gazdaságpolitika számára.

A disszertáció e három kérdés köré épül. Bemutatok egy olyan modellt, ahol kimutatható a tudáshálózatok struktúrájának hatása a gazdaság általános egyensúlyi helyzetére. A modell bemutatásával az is a célom, hogy illeszkedve a hálózati struktúra szerepét vizsgáló gondolati irányvonalba, a tudás-áramlás hálózati struktúrájának makrogazdasági hatásait elemezzem, ezáltal a parciális modellezési keret egy szélesebb kontextusba helyezhető. Megmutatom, hogy a tudáshálózatok explicit modellezése egyrészt kimutatja a hálózati struktúra makrogazdasági teljesítményre gyakorolt hatását, ugyanakkor a korábbi, parciális modellekhez képest új meglátásokkal is gazdagítja a tudás-hálózatokról alkotott képet.

A modellezési feladat mellett további célom, hogy a regionális (régiók közötti) tudás-transzferek empirikus elemzéséhez a modell által szolgáltatott bázison hozzájáruljak, így a modell empirikus teszteléséhez kapcsolódóan szabadalmi együttműködési hálózatok adatait felhasználva elemzem a tudás-áramlás és a teljes tényező-termelékenység közötti kapcsolatot, valamint a modell egészének empirikus relevanciáját. Sikerül kimutatni, hogy a felvázolt modell adekvát leírását szolgáltatja az empirikus hálózatokban tapasztalt jelenségeknek.

Végül pedig egy olyan szimulációs modellkeretet mutatok be, amely a modellezési és empirikus tapasztalatokra építve alkalmas lehet arra, hogy a regionális fejlesztéspolitikai döntéseket a tudás-áramlás hálózati kapcsolatainak explicit figyelembevételével támogassa.

2.4.2. A disszertáció struktúrája

Az irodalmi alapvetést követően a harmadik fejezetben a modell ismertetésére kerül sor. Az alapvető összefüggések leírása mellett itt helyet kap a modell szerves részét képező (itt alkalmazott) hálózati-gráfelméleti módszertan részletesebb ismertetése is, akárcsak a modell egy speciális esetének analitikus levezetése. A speciális esetben a modell vállalatai homogének, ugyanakkor a modell lényegi elemeinek érzékeltetéséhez a heterogén vállalatok feltevését kell használnunk. A speciális eset bemutatására azért kerül sor, mert általános esetben a modell csak numerikus módszerekkel oldható meg, így ez az analitikusan megoldható eset egyfajta referencia-pontként szolgál a továbbiakban.

A negyedik fejezetben a modell működését vizsgálom. Tekintve a modell komplexitását az analitikus megoldás helyett szimulációs technikát alkalmazok, amely segítségével a modell működése különböző peremfeltételek mellett vizsgálható. A hálózati struktúrák közvetlen hatásának vizsgálata mellett dinamikus szimulációkat is bemutatok, amelyek segítségével a hálózati struktúrák és a technológiai diffúzió közötti kölcsönhatás makroszintű hatásainak értelmezésére nyílik lehetőség.

A modell bemutatását és szimulációs vizsgálatát követően a disszertáció második része az empirikus teszteléssel foglalkozik. Ebben a részben a vizsgálat explicit térbeli dimenziót kap, azaz a hálózat csomópontjai régiókként kerülnek definiálásra. Az ötödik fejezet a harmadik fejezet modelljének egy központi elemének empirikus vizsgálatát végzi el: az ott felvetett kérdés az, hogy a hálózatokon keresztül elérhető külső tudás milyen mértékben és milyen feltételek közepette hat az egyes gazdasági egységekre (ebben az esetben régiók) gazdasági teljesítményére, termelékenységre.

A hatodik fejezet ezt követően a vizsgált modell egyik nagyon fontos analitikus következtetésének empirikus bizonyítékát keresi, nevezetesen, hogy a hálózati struktúrát mérő egyes paraméterek gazdasági teljesítményre gyakorolt hatása empirikusan is kimutatható-e. A kapott eredmények biztatóak, ugyanakkor a bemutatott elemzés hangsúlyozottan csak első közelítésnek tekinthető. Ebben a fejezetben kap helyet az empirikus vizsgálatokban alkalmazott regionális tudáshálózatok leíró elemzése.

A hetedik fejezet az empirikus tapasztalatokra építve a harmadik fejezetben bemutatott modell kalibrálását végzi el, majd a negyedik fejezetben alkalmazott szimulációs technikákat (azok egy részét) alkalmazza a kalibrált modellre. A cél az, hogy olyan szimulációk lehetőségét mutassuk be, amelyek alkalmasak lehetnek a fejlesztéspolitika számára hasznos hatásvizsgálatok elvégzésére, amely vizsgálatok a hálózati kapcsolatok és struktúrák szerepét explicit módon figyelembe veszik.

A disszertáció nyolcadik fejezete egy rövid összefoglalást ad, felhívja a figyelmet az elemzés korlátaira és felvet néhány továbbfejlesztési lehetőséget is.

3. fejezet

Az általános egyensúly hálózati kapcsolatokkal bővített modellje

Amint arra az előző fejezet végén kitértem, a disszertáció egyik fő célja, hogy a (tudás-) hálózati struktúrák szerepét egy egyszerű általános egyensúlyi modellbe integrálva, lehetőség nyíljon arra, hogy e struktúrák makrogazdasági outputra gyakorolt hatását vizsgáljuk. Ebben a fejezetben bemutatásra kerül az a modell, amely ezt a lehetőséget tartalmazza.

A modell ismertetése előtt azonban egy fontos értelmezési kitérőt kell tennünk. A modell egy speciális értelemben dezaggregált modell, amelyben a gazdasági egységek egyedi modellezésére kerül sor. Erre a hálózati kapcsolatok struktúrájának explicit figyelembe vétele miatt van szükség. Ugyanakkor fontos megjegyezni, hogy a gazdasági egységek általános fogalomként jelennek meg, és mint ilyenek többféle tartalommal feltölthetők. A modellezési logika azon az elven fut, hogy a hálózati struktúrák figyelembevétele a hálózat csomópontjainak egyedi definiálását teszi szükségessé. A modellezési keretünk megkívánja, hogy ezek a csomópontok gazdasági tevékenységet folytató egységekként kerüljenek definiálásra, ugyanakkor azok dimenziója szabadon megválasztható. A disszertációban az értelmezésnek két alapvető lehetősége merül fel. A modell bemutatása során a csomópontokat vállalatoknak fogjuk fel, az empirikus részekben azonban az elérhető adatok okozta korlátok miatt regionális dimenzióra térünk át. Ez azt jelenti, hogy a hálózat csomópontjaiként nem vállalatokat, hanem régiókat tekintünk. Ami a modellezés makroökonómiai vetületét jelenti, az első, vállalati megközelítés a hagyományosnak nevezhető, aggregált, országos szintű makromodellekkel (CGE-DSGE modellek) mutat rokonságot, míg a régiós megközelítés ezzel szemben inkább a térben dezaggregált SCGE modellek vonulatát követi. A két értelmezési lehetőség közötti eltérésekre az empirikus kérdésekkel foglalkozó fejezetek elején részletesen is kitérek.

3.1. Hálózatok matematikai reprezentációja

Mielőtt a modell ismertetésére sor kerül, mindenképpen szükséges a hálózatok matematikai reprezentációjának alapvető sarokköveit rögzíteni, mivel ez a bemutatandó modell egyik fontos építőköve. Jelen pontban, a modell közgazdasági oldalának bemutatása előtt, mindössze a megfelelő jelöléseket és a mögöttük húzódó összefüggéseket mutatom be, a hálózati struktúrák értelmezésére és a kapcsolódó mutatószámok ismertetésére a 3.4.1. pontban kerül sor.¹

A hálózatokkal a matematika gráfelmélet elnevezésű területe foglalkozik, amely Leonhard Euler híressé vált, a Königsbergi hidak problémájáról írt értekezésével indult útjára (Biggs et al, 1986). A terület azóta, nagy számban magyar matematikusok hozzájárulásai folytán is (König Dénes, Rényi Alfréd, Erdős Pál), jelentős eredményeket ért el a hálózatok matematikai reprezentációja és elemzése terén. A gráfelmélet definíciója szerint egy gráf (vagy hálózat) csomópontok (csúcsok) és élek halmaza. Az élek és csomópontok között az teremt kapcsolatot, hogy minden élhez két csomópont rendelhető, vagy fordítva, minden csomóponthoz az élek egy részhalmaza rendelhető.

A fenti két megfeleltetés a gráfok (hálózatok) kétféle matematikai reprezentációját teszi lehetővé, mindkettő egy valós mátrix segítségével ábrázolja a gráfot. Az első lehetőség az ún. incidencia mátrix, amely sorainak száma megegyezik a csomópontok számával, oszlopainak száma pedig az élek számával. A mátrix elemei ebben az esetben az élek és a csomópontok közötti kapcsolatot mutatják: az elem nulla, ha az adott él és csomópont között nincsen hozzárendelés, és nullától különböző, ha van hozzárendelés. Az elem konkrét értéke ebben az esetben függ attól, hogy a gráf irányított-e vagy sem, illetve hogy az élek súlyozottak-e vagy sem.

Az incidencia mátrixszal szemben egy másik lehetőség az ún. kapcsolati mátrix (adjacency matrix) alkalmazása a hálózat leírására. Egy csomóponttal rendelkező (N elemű) gráfot egy $N \times N$ -es kapcsolati mátrixszal írhatunk le, amely mátrix elemei a sor és az oszlop indexének megfelelő csomópontok közötti kapcsolatot mutatják. A mátrix eleme nulla, ha a két csomópont között nincsen él és nullától különböző, ha van. A kapcsolati mátrix bináris, azaz elemei csak 0 és 1 értékűek lehetnek, abban az esetben, ha az élek súlyozatlanok, ellenkező esetben a mátrix elemei tetszőleges valós értéket felvehetnek. A kapcsolati mátrix szimmetrikus, ha a gráf irányítatlan, irányított gráf esetén azonban nem feltétlenül szimmetrikus. Mindezek alapján tehát egy N elemű gráfot az alábbi, általános formájú kapcsolati mátrixszal írhatunk le:

¹A matematikai reprezentáció tárgyalására e ponton azért van szükség, hogy a modell jelölésrendszere követhető legyen.

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1N} \\ a_{21} & a_{22} & \cdots & a_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ a_{N1} & a_{N2} & \cdots & a_{NN} \end{bmatrix} \quad (3.1)$$

A továbbiakban ezt a reprezentációs formát fogjuk használni. A jelen fejezetben illetve a modell elemzését tartalmazó 4. fejezetben a tudáshálózatot irányítatlan, súlyozatlan hálózatnak tételezzük fel, amiből következik, hogy a kapcsolati mátrix általános eleme a 0 és 1 értékek valamelyikét veheti csak fel: $a_{ij} \in (0; 1)$. Feltesszük azt is, hogy a hálózat szimmetrikus kapcsolatokról áll, azaz $a_{ij} = a_{ji}$. A disszertáció empirikus részeiben (5. és 6. fejezetek) a kapcsolatok kétértékűségének feltevését feloldjuk, ugyanakkor megtartjuk a szimmetriára vonatkozó feltételezésünket.

3.2. Az alapmodell bemutatása

3.2.1. A gazdaság kínálati oldala

A gazdaságot leíró modellek egyik központi eleme a termelési függvény. A termelési függvény a termelés (szélesebb értelemben a gazdasági tevékenység) és a termelés inputjai közötti kapcsolatot írja le. A makroszintű összefüggéseket leíró modellekben a termelés inputjait csupán a termelési tényezőkre korlátozzuk, ahogy ezt a most bemutatandó modellben is tesszük. A termelési függvény általános alakja tehát:

$$y = f(\mathbf{x}) \quad (3.2)$$

ahol y jelöli a termelés outputját, \mathbf{x} pedig a termelési tényezők vektora. A hagyományos modellekben a termelési tényezők vektora többnyire a munkát és a tőkét tartalmazza, valamint az f termelési technológiát adottnak vesszük. Jelen modellben a felhasznált termelési tényezők mellett, azaz inkább azok előtt a technológia játszik meghatározó szerepet. Ennek oka, hogy a tudás-hálózatok szerepe kerül előtérbe, ami a vállalatok közötti tudás-áramlás révén a termelési tényezők felhasználásának hatékonyságát befolyásolja.

Ezen túlmenően, amint azt a továbbiakban látni fogjuk, a későbbi elemzések elvégzése érdekében szükséges specifikálnunk a termelési függvény formáját. Erre nem csupán azért van szükség, hogy a numerikus elemzéseket elvégezhessük, hanem azért is, hogy a tudáshálózatok hatását beépíthessük a modellbe. A hálózatok explicit figyelembe vétele ugyanis azt kívánja meg, hogy a modellt az egyes vállalatok szintjén értelmezzük. Ennek megfelelően a termelési függvényre az alábbi specifikáció adható:

$$y_i = K_i L_i^\alpha, i = 1, \dots, N \quad (3.3)$$

ahol y_i az i -edik vállalat által előállított output, L_i az i -edik vállalat által felhasznált munkamennyiség. Az összefüggésben szereplő K_i tényező speciális, jelen esetben kiemelten fontos szerepet játszik: ez jelöli a vállalat számára hozzáférhető, a termelésben produktívan felhasználható tudást. Ebből a szempontból K_i hasonlítható a „hagyományos” termelési függvények technológiai együttthatójához, vagy teljes tényező-termelékenységhez. A fenti összefüggésből látszólag hiányzik a szintén hagyományosan a termelési függvények részét képező tőke. Ez azonban csak látszólagos. Egyrészt tekinthetünk úgy a tőkére, mint rögzített mennyiségben rendelkezésre álló termelési tényezőre, így a vállalat technológiai tudásába ezt beleszámíthatjuk. Másrészt viszont érvelhetünk úgy is, hogy ugyan a tőkeállomány nem rögzített, azonban a vállalat technológiai (produktív) tudása és a tőke között nem tudunk éles határvonalat húzni, így a tőkeállomány (különálló) explicit szerepeltetése a termelési függvényben nem indokolt.

Ezt az érvelést külön támogatja a hálózatok figyelembe vétele modellünkben: a hálózatokon keresztül áramló tudás esetén a vállalat saját tőkeállománya/tudása és a kívülről, spilloverként, extern hatásként megjelenő tudás közötti határvonal elmosódik. Ehhez természetesen szükséges az a feltevés is, hogy a tudást és a tőkét szinonim fogalmakként kezeljük. Ez a megközelítés úgy is interpretálható, hogy a tőkejavak fizikai formában megtettesült tudást jelentenek. Bár a napi gazdasági gyakorlatban a tőke és a tudás szétválasztása lényeges, egy szélesebb, ha úgy tetszik historikus perspektívában a két fogalom közötti szoros kapcsolat nyilvánvaló.²

A (3.3) termelési függvény paramétere (α) a munka parciális termelési rugalmassága: azt mutatja meg, hogy a munkafelhasználás egy százalékos növekedésével a kibocsátás hány százalékkal növekszik. Használata és interpretációja a közgazdasági szakirodalomban általánosnak tekinthető. A szokásos $0 < \alpha < 1$ feltevést a modell vizsgálata során itt is alkalmazzuk.

A termelési függvény így tehát azt az állítást fogalmazza meg formalizált módon, hogy a vállalatok kibocsátása a felhasznált munka mennyiségétől és a vállalat technológiai tudásától függ (ami lehet fizikai tőkejavakban, termelési eljárásokban, vállalati rutinokban, de akár a vállalati kultúrában megtettesülő speciális tudás is). Eddig a pontig modellünk a közgazdasági irodalomban megszokott formát követi. Új elemünk a hálózatok beépítése a modellbe. Az előző fejezetben kiemeltük, hogy a tudáshálózatok kiemelt szerepet játszanak, elsősorban a tudás-intenzív, magas hozzáadott értékű ágazatokban. A tudáshálózatok modellünkbe történő beépítése a termelési függvény K_i változóján keresztül valósul meg, erre térünk ki a továbbiakban.

Ahhoz, hogy a tudáshálózatok szerepét vizsgálhassunk, a gazdaság termelési oldalát alkotó vállalatok közötti hálózati kapcsolatokat kell megjelenítenünk a modellben. Ezeket a kapcsolatokat a 3.1. alfejezetben bemutatott módszerrel tudjuk modellezni. Feltesszük, hogy a vállalatok közötti hálózatot leíró gráf irányítatlan és súlyozatlan, vagyis egyrészt nem vesszük figyelembe a tudás-áramlás során jelentkező aszimmetriákat, másrészt pedig a vál-

²Lásd még a 2. fejezetben e téma kapcsán elmondottakat

lalatok közötti tudásáramlás intenzitásának esetleges különbségeitől is eltekintünk. Ezek a feltevések kétségtelenül egyszerűsítőek, azonban a bemutatandó modell tartalmazza annak lehetőségét, hogy mind az aszimmetriát, mind pedig a kapcsolati intenzitás változásait bevonjuk az elemzésbe.

A tudáshálózatok explicit figyelembe vételéhez szükséges valamilyen módon a tudás értelmezése is. A gazdaságmodellezési irodalomban elterjedt módon a tudást egy valós számmal reprezentáljuk. Természetesen ez a módszer a tudás számos fontos dimenzióját figyelmen kívül hagyja, azonban egyszerűségénél fogva alkalmas arra, hogy néhány lényeges aspektust megragadjunk és vizsgálhassunk. Lényeges szempont azonban az is, hogy esetünkben a tudás többdimenziós jellege nem explicite a vállalatok által közvetlenül birtokolt tudásterületek sokféleségében jelenik meg, hanem a hálózaton keresztül hozzáférhető adott esetben eltérő jellegű tudás-források tekintetében.

A vállalatok tehát a tudás egy adott szintjével jellemezhetőek, amelyet az ún. tudás-vektor határoz meg. Ha a gazdaságban N számú vállalat működését tételezzük fel, akkor ez a tudás-vektor az alábbi formában írható fel:

$$\mathbf{k} = (k_1, k_2, \dots, k_N) \quad (3.4)$$

A \mathbf{k} vektor elemei az egyedi vállalatok tudásszintjeit reprezentálják. Ezek a tudásszintek a modell exogén változói, vagyis eltekintünk ezek változásától. Kézenfekvő kiegészítés lehet azonban az innovációs folyamat elemzése abban az esetben, amikor a \mathbf{k} vektor elemei valamilyen folyamat szerint változnak. A disszertációban azonban erre a kérdéskörre, a területi korlátok okán, nem térünk ki. A valamennyi vállalat számára adott (3.3) termelési technológia mellett így a gazdaság termelési oldalát a k_i értékek eloszlása is jellemzi.

A tudáshálózatok szerepe ebben a kontextusban az, hogy az egyes vállalatok tudásbázisait összekapcsolja, így a vállalatok által felhasználható, rendelkezésre álló tudás eltér a saját tudásbázistól. Ahhoz, hogy ezt az összefüggést a modellbe építhessük, szükségünk van az egyedi tudásszintek hálózaton keresztül történő aggregálására. Feltevésünk szerint az egyes vállalatok tudása nem tökéletesen helyettesíthető. Ez azt jelenti, hogy a vállalatok mindegyike egy kicsit más technológiai területen működik, így bármely más vállalat tudása értékes többletet jelenthet egy adott vállalat számára. Ez a nem tökéletes helyettesíthetőség azonban értelmezhető úgy is, hogy a vállalatok az azonos technológiai terület (iparág) ellenére más tudás-bázist alakítottak ki: más technikákkal, más eljárásokkal, szervezeti rutinokkal operálnak, így egy másik vállalattól származó tudás e különbségek révén hordozza azt a szinergiát, ami a nem tökéletes helyettesíthetőségben nyilvánul meg. Mindezek alapján a különböző vállalatoktól származó tudás aggregálását az alábbi CES technológia mentén végezzük el:

$$K_i = k_i + \left[\sum_{j=1}^N \alpha_{ij} (\theta k_j)^\rho \right]^{\frac{1}{\rho}}, i = 1, \dots, N \quad (3.5)$$

A fenti egyenletre a továbbiakban *tudás-aggregátorként* fogunk hivatkozni, utalva arra, hogy ez az összefüggés adja meg a külső, más gazdasági egységektől hozzáférhető tudás összegzésének módját. A (3.5) egyenlet jobb oldalán szereplő K_i a (3.3) termelési függvényből már ismert, a vállalat által felhasználható, hozzáférhető tudást jelöli. k_i az i -edik vállalat saját tudásszintje, amely egy az egyben hozzájárul a felhasználható tudáshoz. A többi vállalattól származó tudás aggregált „értékét” adja meg a jobb oldali zárójelben található kifejezés, amely a jól ismert Dixit-Stiglitz aggregátor egy speciális formája. ρ az egyes vállalatok tudása közötti helyettesítés paramétere, a helyettesítés rugalmassága $1/(1 - \rho)$.

A helyettesítési paraméter értékére a $0 < \rho < 1$ kikötést tesszük, amire azért van szükség, hogy a CES aggregátorban a adódó „isoquantok” az origóra konvexek legyenek. Ez a kitétel tulajdonképpen annak a könnyen belátható összefüggésnek felel meg, hogy a partner-vállalatoktól származó tudás (k_j) határtermelékenysége csökkenő. A két szélsőséges lehetőséget azért zárjuk ki, mivel $\rho = 0$ esetén a numerikus számítások ütköznek akadályokba, illetve $\rho = 1$ esetén a helyettesítés tökéletes lenne és ezáltal eltűnne a hálózati kapcsolatok diverzitásának jelentősége.

A (3.5) aggregátorban szereplő α_{ij} a korábban definiált \mathbf{A} kapcsolati mátrix megfelelő elemeire vonatkozik. Mivel α_{ij} értéke csak nulla és egy lehet, ezért jelentősége abban áll, hogy az aggregátorban csak azon vállalatok tudása adódik össze, amelyek az adott i -edik vállalat közvetlen szomszédjai a hálózatban.³ További paraméter θ , amely a tudásáramlás vagy tudás spilloverek erősségét méri. Értéke definíció szerint 0 és 1 közé esik: ha értéke 0, akkor a partnerek tudásából semmi nem érzékelhető, ha értéke 1, akkor maximálisan képes a vállalat a partnerek tudását felhasználni. Az egységnyinél kisebb érték azért releváns, mivel egyrészt az egyes vállalatok közötti különbségek miatt, másrészt pedig a kommunikáció eleve adott információs torzításának okán nagy valószínűséggel a partnerek tudásának csupán egy része válik használhatóvá a tudástranszfert követően. Cohen és Levinthal (1990) nyomán a θ paraméter értelmezhető a vállalatok abszorpciós képességeként, vagyis azon képességként, hogy a környezetükből származó információkat, tudást milyen mértékben képesek saját tudásbázisukba integrálni. E szempontból természetesen a paraméter értelmezése meglehetősen restriktív, mivel az abszorpciós képességek nem függetlenek a vállalat jellemzőitől (saját tudás nagysága, kutatás-fejlesztési ráfordítások, stb.) de környezeti tényezőktől sem (amilyen például a technológiai lehetőségek szerepe az iparágban, vagy a tudás jellege). Carayol és Roux (2009) nyomán a θ paraméter értelmezhető a tudás tacit vagy kodifikált jellege szempontjából is. E szerint a megközelítés szerint a tudás tacit vagy kodifikált jellegétől függően kevésbé vagy jobban transzferálható, így a tudásáramlás során keletkező veszteségek attól függenek, hogy milyen típusú tudás átadására (áramlására) kerül sor. Így θ alacsony értéke inkább tacit, míg θ magasabb értéke inkább kodifikált tudásra utal. Ez a megközelítés továbbá lehetőséget ad arra is, hogy a tudás-hálózatok szerepét különböző tudás-jellemzők mellett vizsgáljuk, kiemelve, hogy a

³Természetesen a (3.5) aggregátor súlyozott hálózati kapcsolatok esetén is releváns: ekkor a külső partnerektől származó tudás-elemek egyfajta súlyozott átlagként adódik a vállalat által hozzáférhető tudás.

tudás (tacit vagy kodifikált) jellege nagy mértékben meghatározza egy ágazat térbeli koncentrációjának mértékét (Sorenson, 2005).

Egyszerű modellünk kínálati oldalát tehát három tényező adja: a vállalatok \mathbf{k} tudás-vektora, a vállalatok közötti kapcsolatokat leíró \mathbf{A} kapcsolati mátrix, az ezek alapján megállapított (3.5) tudás-aggregátor, valamint a vállalatok kibocsátását meghatározó (3.3) termelési függvény.

A gazdaság modellezése során a közgazdasági irodalomban elterjedt monopolisztikus versenymodellt alkalmazom. Ennek lényegi elemeit az előző fejezetben már bemutattam, itt csupán arra térek ki, hogy a jelen kontextusban miért célszerű ezt a formát választani. A tökéletes versenypiac feltevése szerint a piacon végtelen sok, de legalábbis nagyon sok eladó és vevő van jelen valamint az eladók homogén, a fogyasztók számára az áron kívül más jellemzőjükben megkülönböztethetetlen termékeket állítanak elő. Egy ilyen piacon nyilván nem csak a vevők nem tesznek különbséget az eladók között, hanem az eladók sem tesznek különbséget versenytársaik között. A modell kínálati oldalával, vagyis a vállalatok leírásával azonban ez a piac-felfogás nem egyeztethető össze, aminek két közvetlen oka van.

Egyfelől a partner-vállalatoktól származó tudás-elemek korlátozott helyettesíthetősége miatt szükséges a tökéletes verseny és ezáltal a vállalatok homogenitásának feladása. Ha ugyanis a vállalatok tudás-bázisai egymást korlátozottan helyettesítik, az a vállalatok tudása és ezáltal az alkalmazott technológiák (folyamatok, rutinok, stb.) között létező különbségeket implikál. Így a vállalat által előállított termékek is, legalábbis néhány dimenzió mentén és minimálisan, különbözőek lesznek, így a termékek tökéletes helyettesíthetősége már nem alkalmazható feltevés.

Másfelől a hálózati kapcsolatok explicit modellezése kívánja meg a tökéletes versenytől és a homogén vállalatoktól eltérő piaci struktúra feltevését. Ennek jelentősége akkor mutatkozik meg, amikor a vállalatok hálózati kapcsolatait endogenizáljuk, vagyis amikor a vállalatok saját maguk dönthetnek kapcsolatok létrehozásáról vagy megszüntetéséről. Ilyen esetekben ugyanis egy adott kapcsolat értéke a vállalat számára attól függ, hogy a másik vállalat milyen addicionális tudást képes nyújtani az adott vállalat számára. Így ahhoz, hogy a hálózati kapcsolatokról szóló döntés ne pusztán a kapcsolatok számáról történő döntésre redukálódjon, hanem valóban a konkrét partnerek kiválasztása is jelen legyen a döntésben, ahhoz a potenciális partnereknek különbözőeknek kell lenniük, vagyis a vállalatnak differenciálni kell tudni a lehetséges partnerek között.

3.2.2. A gazdaság keresleti oldala

A gazdaság keresleti oldalát is a monopolisztikus verseny feltevése határozza meg. Mint-hogy a vállalatok monopolisztikusan versenyzőek, így az általuk előállított termékek a fogyasztók számára nem tökéletes helyettesítők. Jelölje az i -edik vállalat által előállított termékből fogyasztott mennyiséget x_i . A fogyasztók az N vállalat által előállított különböző

termékek fogyasztásából jutnak hasznossághoz és a hasznossági függvényt Dixit és Stiglitz (1977) modellje alapján az alábbi formában írjuk fel:

$$U = \left(\sum_{i=1}^N x_i^\sigma \right)^{\frac{1}{\sigma}} \quad (3.6)$$

A hasznossági függvény fenti specifikációja konstans helyettesítési rugalmasságot feltételez az egyes termékek között, amelynek értéke: $\varepsilon = 1/(1 - \sigma)$. Akárcsak a korábban definiált tudás-aggregátorban a ρ paraméter, itt σ értelmezhető helyettesítési paraméterként az egyes termék-variánsok tekintetében. A paraméter értékére kikötjük a $0 < \sigma < 1$ feltételt, aminek az a jelentősége, hogy a hasznossági függvény közömbösségi görbéi (hiperfelületei) az origóra konvexek lesznek, ami az egyes termékek csökkenő határhasznát mutatja. Amennyiben $\sigma > 1$, úgy a határhaszon növekvő lenne, ami ellentmond a mindennapi tapasztalatnak.

A háztartások által elkölthető összes nominális jövedelmet jelölje I . Így a háztartások költségvetési korlátja egyszerűen a következő alakot ölti:

$$I = \sum_{i=1}^N p_i x_i \quad (3.7)$$

Értelemszerűen adottnak véve a rendelkezésre álló I jövedelmet, a háztartások hasznosság-maximalizációs problémája a (3.6) hasznossági függvény maximalizálását jelenti a (3.7) költségvetési korlát figyelembevételével. A függelékben megtalálható levezetés alapján a fenti probléma megoldásaként az i -edik termék keresletére az alábbi összefüggést kapjuk:

$$x_i = p_i^{-\varepsilon} \frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}}, \quad i = 1, \dots, N \quad (3.8)$$

ahol $\varepsilon = 1/(1 - \sigma)$ a termék-variánsok közötti helyettesítés rugalmasságát jelöli. A kifejezés jobb oldalán található hányados tekinthető egyfajta reáljövedelemként is. A nevezőben található összeg ekkor speciális árszínvonalként értelmezhető, így a nominális jövedelem és az árszínvonal hányadosa adja a reáljövedelmet.⁴

E levezetések során tehát rendelkezésünkre áll a modell-gazdaság egy első leírása, a kínálati oldalt alkotó \mathbf{k} tudás-vektor, \mathbf{A} kapcsolati mátrix, (3.5) tudás-aggregátor és (N) darab (3.3) termelési függvény, valamint a keresleti oldalt meghatározó (szintén N darab) (3.8) keresleti függvény segítségével.

⁴Meg kell itt jegyeznünk, hogy a nevezőben található összeg nem tekinthető precíz árszínvonal-definíciónak. Dixit és Stiglitz (1977) modelljében az árszínvonal definíciója a fenti összeg $1/(1 - \varepsilon)$ -adik hatványa, így valóban egyfajta átlag keletkezik. Igaz ugyanakkor, hogy ebben a kontextusban az árszínvonal $(1 - \varepsilon)$ -adik hatványával osztjuk az összes nominális jövedelmet, ami szintén nem „tökéletes” reáljövedelem.

3.2.3. Általános egyensúly

A gazdaság egyensúlyi helyzetének meghatározásához szükséges egy további elem is, ez pedig a vállalatok profitmaximalizációs döntése. A fenti modell-gazdaságban a vállalatok profitfüggvénye a következő:

$$\pi_i = p_i y_i - wL_i - rs_i, i = 1, \dots, N \quad (3.9)$$

ahol w egy egységnyi munka költsége (munkabér), s_i a vállalat által fenntartott hálózati kapcsolatok száma, míg r egy kapcsolat fenntartásának a költsége. A vállalat kapcsolatainak száma egyszerűen felírható a kapcsolati mátrix segítségével:

$$s_i = \sum_{j=1}^N a_{ij}, i = 1, \dots, N \quad (3.10)$$

A profitfüggvény fenti specifikációjában a hálózati kapcsolatokkal kapcsolatos költségek egyenesen arányosak a kapcsolatok számával. Ez első megoldásként értelemeszerűnek tűnik, azonban más specifikációk is elképzelhetők. Mivel azonban a vállalatok hálózati kapcsolatokra vonatkozó döntéseivel jelen esetben nem foglalkozunk, a profitfüggvény utolsó tagja tulajdonképpen fix költségként jelenik meg, ami a profitmaximalizáció során eliminálódik, így a gazdaság egyensúlyi helyzetét végső soron nem befolyásolja. A hálózati kapcsolatokhoz kötődő költségek meghatározásával éppen ezért itt nem foglalkozunk, ez a kérdés a hálózati kapcsolatok endogenizálása esetén merül fel élesen, ami viszont a terjedelmi korlátok okán nem képezi a disszertáció részét.

Mint hogy a gazdaság általános egyensúlyi helyzetét keressük, így valamennyi piacon egyensúlyt kell feltételeznünk. Esetünkben ez N darab termékpiac egyensúlyát jelenti, amelyet egyenként az $x_i = y_i$ egyenlőségek írnak le, továbbá a munkapiacra vonatkozó egyensúlyi feltételt, amire a továbbiakban kitérünk. Felhasználva a termékpiacok egyensúlyi feltételeit, a termelési függvény inverzét, valamint a keresleti függvényt a (3.9) profitfüggvényt az alábbi formára hozhatjuk:

$$\pi_i = p_i^{1-\varepsilon} \frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} - wK_i^{-1/\alpha} p_i^{-\varepsilon/\alpha} \left(\frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} \right)^{\frac{1}{\alpha}} - rs_i, i = 1, \dots, N \quad (3.11)$$

Mint hogy a kapcsolatokat adottnak vesszük, ezért az \mathbf{A} mátrix elemei exogén adottságként jelennek meg. Így az eleve adott \mathbf{k} tudásvektor és a kapcsolati mátrix meghatározza a vállalatok K_i rendelkezésre álló tudásbázisát, ami ezek szerint a vállalatok számára adottságként jelenik meg, akár csak a kapcsolatok rögzítettségéből fakadóan a kapcsolati költségek (rs_i) és a munkabér (w). A vállalat számára adottság még ezen kívül az összes nominális jövedelem (I) és a versenytársak árai is (p_j). Így viszont a (3.11) profitfüggvény a vállalatok szemszögéből csupán egyetlen döntési változót tartalmaz, a termék árát (p_i).

A fenti profitmaximalizációs feladat megoldása során szokásos feltevés az, hogy a vállalatok egyenként relatíve kicsinyek a piac egészéhez viszonyítva, így a saját árainak a (3.11) profitfüggvényben található $\sum_j p_j^{1-\varepsilon}$ összegre gyakorolt hatását elhanyagolhatónak találják. Ez a technikai megoldás a levezetéseket és a kapott eredményeket egyszerűsíti, ugyanakkor lényegi torzításokat nem okoz a következtetések szempontjából. Figyelembe véve ezt az egyszerűsítést, valamint azt a korábbi megállapításunkat, hogy a vállalatok által felhasznált munka ugyan változhat, a kapcsolatok és ezen keresztül a kapcsolatokkal kapcsolatos költségek rögzítettek (és ezzel együtt a kibocsátás és az ár sem változik a kapcsolatok számának változása miatt), a vállalatok optimális árdöntésére az alábbi összefüggés adódik:

$$p_i = w^\varphi K_i^{-\varphi/\alpha} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^\varphi \left(\frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} \right)^{\frac{1-\alpha}{\alpha}\varphi}, \quad i = 1, \dots, N \quad (3.12)$$

ahol φ az α és σ paraméterek függvénye: $\varphi = (\alpha - \alpha\sigma)/(1 - \alpha\sigma)$. A fenti összefüggés tehát azt reprezentálja, hogy a vállalat profitmaximalizáló ára a munkabértől (w), a vállalat által hozzáférhető tudástól (K_i), a versenytársak áraitól (p_j), a nominális jövedelemtől (I) és a modell strukturális paramétereitől (α és σ) függ. Az eredmény reprodukálja az ilyen profitmaximalizációs döntésektől „elvárható” jellemzőket. Minthogy φ értéke pozitív, ezért a bérek növekedése az árakat növeli. A versenytársak árainak növekedése szintén pozitívan hat a saját termék árára, akárcsak az összes nominális jövedelem növekedése is. Ezzel szemben a vállalatok tudásának növekedése az optimális árat csökkenti.

A monopolisztikus verseny modelljében tipikus feltevés, hogy a profit zérus. Ennek azonban két fontos előzménye van. Egyrészt a „tankönyvi” modell szimmetrikus vállalatokkal dolgozik, másrészt pedig a vállalatok száma endogén, mivel éppen a szabad be- és kilépés teszi lehetővé a profit eltűnését. Modellünkben egyrészt nem érvényesül a szimmetria, másrészt pedig rögzített vállalatszám (N) dolgozunk.⁵ Ezen okoknál fogva nem tesszük fel a profit zérus voltát.

A modell lezárásaként a munkapiac egyensúlyi helyzetét biztosító egyenletet kell meghatározunk. Ehhez figyelembe kell vennünk, hogy a vállalatok optimális árdöntése az adott peremfeltételek közepette meghatározza a kibocsátás (y_i) és a felhasznált munkaerő mennyiségét (L_i) is. Modellünkben a munkakínálati döntést nem vesszük explicit módon figyelembe, a munkakínálatot adottnak vesszük. Ezt az exogén munkakínálatot \bar{L} -sal jelölve a munkapiac egyensúlyi helyzetét az alábbi egyszerű összefüggés írja le:

$$\sum_{i=1}^N L_i = \bar{L} \quad (3.13)$$

Így tehát a modellt le is zártuk. A gazdaság általános egyensúlyi helyzetét $N + 1$ darab egyenlet írja le, amiből N darab a vállalatok profitmaximalizáló árára felírt (3.12) összefüggés.

⁵ Ennek az az oka, hogy a később bevezetendő hálózati módszertan szempontjából praktikusabb és kezelhetőbb modelleket kapunk.

géseket jelenti, valamint a munkapiaci egyensúlyt leíró (3.13) egyenletet. Ez az $N+1$ egyenlet tartalmazza az általános egyensúly valamennyi feltételét, mivel a (3.12) egyenletek már tartalmazzák a háztartások optimális (hasznosságot maximalizáló) döntését csakúgy, mint a termékpiaci egyensúlyi helyzetek feltételét, valamint a vállalatok profitmaximalizációs döntését is. Ezt egészíti ki a (3.13) egyenlet a munkapiaci egyensúly feltételével, így tehát adott valamennyi piac egyensúlyi feltétele, továbbá valamennyi szereplő optimális döntése. Az egyensúlyt leíró egyenletrendszer az alábbi:

$$p_i = w^\varphi K_i^{-\varphi/\alpha} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^\varphi \left(\frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} \right)^{\frac{1-\alpha}{\alpha}\varphi}, \quad i = 1, \dots, N \quad (3.12')$$

$$\sum_{i=1}^N \left[p_i^{-\varepsilon} \frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} \right]^{\frac{1}{\alpha}} K_i^{-1/\alpha} = \bar{L} \quad (3.14)$$

Az $N+1$ egyenlethez $N+1$ változó tartozik: az árvektor ($\mathbf{p} = (p_1, p_2, \dots, p_N)$) és a munkabér (w). Az egyenletrendszer, vagyis a modell számára adottságot jelentenek értelemszerűen az α és σ paraméterek, ezen túl pedig az exogén hálózati kapcsolatok miatt a rendelkezésre álló tudásbázisok vektora (a K_i értékek), a rendelkezésre álló munkamennyiség (\bar{L}), valamint az összes nominális jövedelem (I).

A fenti felsorolásból talán a nominális jövedelem exogén volta igényel némi magyarázatot, mivel első megközelítésben a gazdaság egyensúlyi helyzete befolyásolni látszik az összes jövedelmet. A megoldás abban rejlik, hogy I a nominális jövedelem és hogy a modellünk, bár az árakat explicite kezeljük, valójában reálmodell. Az árak konkrét nagyságára éppen azért tudunk speciális értéket meghatározni, mert adott az összes nominális jövedelem. Ebből a szempontból tulajdonképpen azt is mondhatjuk, hogy az I változó nem csupán a nominális jövedelmet, hanem a gazdaság rendelkezésére álló pénzmennyiséget is jelenti.

A (3.12) és (3.14) egyenletek által meghatározott egyensúlyi helyzet megadása általános esetben analitikus módszerekkel nem lehetséges, így két eltérő módszert követhetünk. Egyrészt valamely speciális esetet figyelembe véve végezhetjük el az analitikus megoldást, másrészt pedig numerikus módszereket alkalmazhatunk, amihez viszont a paraméter-értékek specifikálására van szükségünk. A továbbiakban mindkét eljárást alkalmazzuk. A 3.3. alfejezetben egy speciális esetet mutatok be, amely a vállalatok szimmetrikus voltán alapul, majd a 4. fejezetben az aszimmetrikus (általános) esetet numerikus szimulációk segítségével vizsgáljuk meg.

3.3. Egy speciális eset – szimmetrikus vállalatok

Az előző fejezetpontban bemutatott alapmodell, mint arra kitértünk, analitikus módszerekkel nem oldható meg. Ha azonban néhány szigorúbb megszorítást teszünk, azaz a modell

egy speciális esetét vizsgáljuk, akkor a megoldás lehetségessé válik és így bizonyos speciális megállapításokat tehetünk, amelyek aztán a numerikus szimulációk során az általánosabb esetben igazolhatóak vagy cáfolhatóak.

Jelen esetben az egyszerűsítést, vagy speciális esetet az jelenti, hogy feltételezzük, hogy a vállalatok által hozzáférhető tudásbázis minden vállalat esetében azonos, vagyis $K_i = \hat{K}$ minden i -re. A hálózat szempontjából ez a kettős feltevésel egyezik meg, hogy egyrészt valamennyi vállalat saját tudása megegyezik (azaz $k_i = \hat{k}$ minden i -re), másrészt pedig valamennyi vállalat pontosan ugyanannyi kapcsolattal rendelkezik. Ezen kívül természetesen ez a helyzet előállhat úgy is, hogy a tudásvektor elemei nem egyformák, de a hálózati kapcsolatok speciális struktúrája éppen ellensúlyozza ezeket a differenciákat az egyéni tudásszintekben.

Fontos kiemelnünk, hogy e speciális eset tárgyalása mindössze technikai célokat szolgál. Az itt foglalt feltevések a fokszám és a tudásszintek homogenitásáról természetesen valóság-idegenek, ezen felül ellentmondanak a 2. fejezetben tett azon megállapításnak, hogy a tudás erősen kontextus-függő, így a homogén tudásbázisok létrejtte ugyan nem lehetetlen, de elhanyagolható valószínűségű. A jelen alfejezet szerepe, hogy a modellnek egy olyan speciális esetét mutassa be, amely analitikus eszközökkel kezelhető, így egyfajta „zsinórmértékül” szolgálhat a későbbi, általános esetre végzett numerikus szimulációk értékelésekor.

Felhasználva a $K_i = \hat{K}$ egyezőséget, a vállalatok profitmaximalizáló árára a (3.12) egyenlettel analóg összefüggést kapunk:

$$p_i = w^\varphi \hat{K}_i^{-\varphi/\alpha} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^\varphi \left(\frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} \right)^{\frac{1-\alpha}{\alpha}\varphi}, \quad i = 1, \dots, N \quad (3.15)$$

Minthogy tetszőleges \mathbf{p} vektor esetén az utolsó zárójelben lévő $\sum_j p_j^{1-\varepsilon}$ kifejezés minden vállalat számára azonos, így az egyes vállalatok által megállapított ár is egyforma lesz. Ennek az az egyszerű oka, hogy a (3.12) összefüggésben szereplő egyetlen vállalat-specifikus elem K_i volt, ami most már minden vállalat számára azonos, következésképpen a vállalatok által megállapított ár is azonos lesz. Így a fenti képlet az alábbi formában írható fel:

$$\hat{p} = w^\varphi \hat{K}^{-\frac{\varphi}{\alpha}} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^\varphi \left(\frac{I}{N\hat{p}^{1-\varepsilon}} \right)^{\frac{1-\alpha}{\alpha}\varphi}, \quad i = 1, \dots, N \quad (3.16)$$

Minthogy a (3.16) egyenlet minden vállalat számára azonos, ezért az általános esettel szemben most már élhetünk a reprezentativitás feltevésével, aminek következtében a (3.12) összefüggés által meghatározott N darab egyenlet csupán egyetlen egyenletre redukálódik. A (3.16) egyenletet \hat{p} -ra rendezve a vállalatok (vagy másképpen a reprezentatív vállalat) optimális árát kapjuk:

$$\hat{p} = w^{\frac{\varphi}{\gamma}} \hat{K}^{-\frac{\varphi}{\alpha\gamma}} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^{\frac{\varphi}{\gamma}} \left(\frac{I}{N} \right)^{\frac{1-\alpha}{\alpha} \frac{\varphi}{\gamma}} \quad (3.17)$$

ahol $\gamma = 1 + \varphi(1 - \varepsilon)(1 - \alpha)/\alpha$. Az egyensúlyi árat tehát fel tudjuk írni a modell paramétereinek, exogén adottságként kezelt változóinak és a munkabérnek a függvényében. Ezek közül ez utóbbi a lényeges szempont, ugyanis azt látjuk, hogy bármely munkabér-szint mellett más lesz az az árszint, amely a termékpiacon (a szereplők optimális döntése mellett) egyensúlyba hozza. A kérdés tehát az, hogy melyik lesz az a bérszint, amelyre az általános egyensúly fennáll, vagyis a munkapiac is egyensúlyba kerül. A (3.17) egyenlet segítségével meghatározott árszintet a keresleti függvénybe helyettesítve kapjuk meg a reprezentatív vállalat kibocsátásának optimális szintjét:

$$\hat{y} = w^{-\frac{\varphi}{\gamma}} \hat{K}^{\frac{\varphi}{\alpha\gamma}} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^{-\frac{\varphi}{\gamma}} \left(\frac{I}{N} \right)^{1 - \frac{1-\alpha}{\alpha} \frac{\varphi}{\gamma}} \quad (3.18)$$

Látható, hogy a kibocsátás szintje a modell paramétereinek és exogén változóinak mellett a munkabér szintjétől is függ. Az adott tudásszint (\hat{K}) mellett a (3.3) termelési függvény egyértelmű kapcsolatot teremt a kibocsátás és a munkafelhasználás között, így a kibocsátás optimális szintje egyúttal a munkafelhasználás optimális szintjét is megadja:

$$\hat{L} = w^{-\frac{\varphi}{\gamma\alpha}} \hat{K}^{\frac{\varphi}{\alpha^2\gamma} - \frac{1}{\alpha}} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^{-\frac{\varphi}{\gamma\alpha}} \left(\frac{I}{N} \right)^{\left(1 - \frac{1-\alpha}{\alpha} \frac{\varphi}{\gamma}\right) \frac{1}{\alpha}} \quad (3.19)$$

Az előbbieknél megfelelően, értelemszerűen a munkafelhasználás is a bérszinttől függ. A munkapiac egyensúlyi feltétele jelen esetben az alábbi formára egyszerűsödik:

$$N\hat{L} = \bar{L} \quad (3.20)$$

Behelyettesítve az \hat{L} -ra kapott összefüggést már csupán egyetlen változó marad, amit meg kell határoznunk, ez pedig a munkabér. A (3.20) egyenlet tulajdonképpen (behelyettesítve a (3.19) egyenletet, amely már tartalmazza az optimális és egyben termékpiacon egyensúlyt garantáló árakat) az egyensúlyi bérszintet definiálja, amely mellett valamennyi piac egyensúlyba kerül. Ez a bérszint:

$$\hat{w} = \alpha \frac{\varepsilon - 1}{\varepsilon} \hat{K}^{\eta} I^{1-\eta} N^{\eta} \bar{L}^{\eta\alpha-1} \quad (3.21)$$

ahol $\eta = 1/\alpha - \gamma/\varphi$. Könnyen megmutatható azonban, hogy $\eta = 0$ α és ε bármely értéke mellett, így a bérré kapott kifejezés a következő formára egyszerűsödik:

$$\hat{w} = \alpha \frac{\varepsilon - 1}{\varepsilon} \frac{I}{\bar{L}} \quad (3.21')$$

Az egyensúlyi bér tehát kifejezhető a modell strukturális paramétereinek és két exogén változójának függvényében. A munka parciális termelési rugalmassága pozitív kapcsolatban áll a bérrrel: a termelési rugalmasság növekedése magasabb bérszintet eredményez. Ez logikus is, hiszen a termelési rugalmasság növekedése kvázi a munka termelékenységének növekedését is jelenti. A termék-variánsok közötti helyettesítés rugalmassága (ε) szintén pozitív hatással van a bérszintre. Logikus a nominális jövedelem hatása is, hiszen a bérszint is nominális bérszintet jelöl, nem reálbért. Ugyanakkor a rendelkezésre álló munka mennyisége negatívan befolyásolja a bérszintet: magasabb munkakínálat értelemszerűen alacsonyabb béreket eredményez, minden egyéb változatlanlansága mellett.

Nagyon érdekes eredmény ugyanakkor, hogy az egyensúlyi bérszintre nincsen hatással a vállalatok tudásszintje, \hat{K} . Ha azonban a modell többi endogén változójának egyensúlyi értékét vizsgáljuk, akkor a tudásszint és ezáltal a hálózatok hatása már megjelenik az eredményekben. Az egyensúlyi bérszintet a kibocsátásra kapott (3.18) egyenletbe visszahelyettesítve azt kapjuk, hogy

$$\hat{y} = I^{1-\frac{\varphi}{\alpha\gamma}} \hat{K}^{\frac{\varphi}{\alpha\gamma}} \bar{L}^{\frac{\varphi}{\gamma}} N^{\frac{1-\alpha}{\alpha}\frac{\varphi}{\gamma}-1} \quad (3.22)$$

Vizsgáljuk most meg az egyes változók hatását a kibocsátás volumenére. A fenti összefüggésben szereplő φ és γ összevont paramétereket az alábbi egyszerűbb formában írhatjuk fel:

$$\varphi = \alpha \frac{1 - \sigma}{1 - \alpha\sigma}$$

$$\gamma = \frac{1 - \sigma}{1 - \alpha\sigma}$$

Ebből következik, hogy

$$\varphi = \alpha\gamma$$

Ezek alapján a (3.22) kifejezésben található kitevők meglehetősen egyszerű formára hozhatóak, és a kibocsátásra kapott egyenlet az alábbi formát ölti:

$$\hat{y} = \hat{K} \left(\frac{\bar{L}}{N} \right)^\alpha \quad (3.22')$$

A fenti eredmény több fontos következtetéssel is szolgál. Egyrészt látható, hogy a nominális jövedelem „kinullázódott”, azaz értéke nem játszik szerepet a reálkibocsátás meghatározásában. Ez alátámasztja azt a korábbi megállapításunkat, hogy a makroökonómiai dichotómia fennállása miatt a nominális pénzmenyiségnek az árak konkrét nagyságának meghatározásán túl nincsen szerepe a modellben. A (3.22') kifejezés második tényezője az

egy vállalatra jutó munkaerő mennyiségét adja meg, így a kibocsátásra kapott összefüggés tulajdonképpen reprodukálja a (3.3) termelési függvényt, ami reális következtetésként adódik.

3.4. Hálózati struktúrák értelmezése

Az előbbiekben bemutattam azt az egyszerű makroökonómiai modellt, amely lehetőséget ad arra, hogy a tudáshálózatok szerepét értelmezzük és értékeljük a modell keretein belül. Ehhez azonban a hálózatok explicit figyelembevételére van szükség. Arra is kitértünk, hogy a hálózatok reprezentációja egy $N \times N$ -es bináris mátrix segítségével valósítható meg. A hálózat struktúráját e mátrix egy adott realizációja, azaz a mátrix elemeinek egy adott kombinációja jelenti. Könnyen igazolható, hogy N alacsony értéke esetén is rendkívül sok ilyen kombináció létezhet, így a hálózati struktúra ilyen szempontból történő kezelése meglehetősen nehézkes volna.

Egy kézenfekvő lehetőséget jelent a hálózati struktúrák vizuális elemzése. Ez azonban kisebb elemszámú hálózatok esetében működhet megfelelően, ahol a csomópontok és a kapcsolatok még jól elkülöníthetőek. Egy nagyobb elemszámú, és főként sűrűbb hálózat esetén a vizuális megjelenítés ugyan nem lehetetlen, de a valós struktúrák felfedezése egyre nehezebbé válik. Éppen ezért szükség van valamiféle támpontra ahhoz, hogy a hálózat struktúráját kezelni tudjuk, vagy másként, hogy a kapcsolati mátrix rendkívül nagy számú lehetséges kombinációit valamilyen elv szerint csoportokba vagy sorrendbe rendezhessük. Erre egy jó lehetőséget nyújtanak a társadalmi hálózatelemzés (Social Network Analysis – SNA) által kifejlesztett és mind szélesebb körben alkalmazott hálózati mutatók.

A társadalmi hálózatok elemzése meglehetősen hosszú múltra tekint vissza, elméleti megalapozása visszanyúlik Émile Durkheim munkásságához, aki a társadalmi jelenségeket az egyéni cselekvésen túlmutató, az egyének közötti interakciók talaján létrejövő jelenségeknek tekintette (Durkheim, 1893). Később a társadalmi kapcsolathálóok elemzése lendületet vett és mára széles irodalom foglalkozik a társadalmi kapcsolathálóok kérdésével egészen különböző tudományterületeken a genetikától kezdve a technológiai diffúzió át a járványbiológiáig (Scott, 1991; Wasserman és Faust, 1994). Az innováció és a diffúzió kérdései az előző fejezetben részletesebben is előkerültek.

A társadalmi kapcsolathálóok elemzése és a már említett gráfelmélet között szoros kapcsolatok fedezhetőek fel. A társadalmi kapcsolathálóok elemzésének módszertani alapjait a gráfelmélet adja, s az előbbi tulajdonképpen az utóbbi egyfajta praktikus alkalmazásának tekinthető. A továbbiakban a disszertációban alkalmazott hálózati mutatószámok és hálózati modellek bemutatására kerül sor. Ez tulajdonképpen azt jelenti, hogy az előző alfejezetben exogén paraméterként (paraméterek halmazaként) kezelt kapcsolati mátrix meghatározásának módját és e mátrix (valamint az általa reprezentált hálózati struktúra) fő jellemzőit tükröző mutatószámokat deklaráljuk.

3.4.1. SNA mutatók

A társadalmi kapcsolatháló elemzésének egyik lényeges pontja, hogy a sokféle és komplex hálózati struktúrák világában valamiféle rendszert találjon. Ennek egyik, általunk is használt módja, hogy a hálózat egészének vagy a hálózat tagjainak jellemzőit valamilyen mutatószámok formájában próbáljuk megragadni. A számos rendelkezésre álló mutató közül jelen disszertációban csupán néhányat emelünk ki, amelyek a hálózati struktúrák különbségeit alkalmasan leírják. A hálózati mutatók széles köréről Scott (1991) valamint Wasserman és Faust (1994) összefoglaló munkái adnak szélesebb képet. A mutatók köre két fő csoportra osztható: azon mutatók csoportjára, amelyek a hálózat egy tagjának (csomópontjának) helyzetét számszerűsítik (lokális mutatók), illetve azon mutatók csoportjára, amelyek a hálózat egészének valamilyen jellemzőjét reprezentálják (globális mutatók). A hálózati mutatók bemutatása során a kiindulási pontunk a már bevezetett \mathbf{A} kapcsolati mátrix, melynek a_{ij} általános eleme 1, amennyiben az i és j csomópont között létezik kapcsolat és 0, ha nem létezik ilyen kapcsolat.⁶

Az egyik legalapvetőbb lokális hálózati mutató az egy csomópont által birtokolt kapcsolatok száma. Ezt a társadalmi hálózatelemzés a kapcsolatok fokszámának (degree) nevezi. A kapcsolati mátrix segítségével egy csomópont fokszáma könnyen felírható:

$$s_i = \sum_{j=1}^N a_{ij} \quad (3.23)$$

Ahol N a hálózat tagjainak (csomópontjainak) számát jelöli. Míg a fokszám egy lokális mutató, természetesen képezhetünk egy analóg globális mutatót is, ami az egyedi fokszámok átlagaként adódik, ezt átlagos fokszámnak (average degree) nevezzük:

$$as = \frac{\sum_{i=1}^N \sum_{j=1}^N a_{ij}}{N} \quad (3.24)$$

Míg az egyedi (lokális) fokszám viszonylag jól jellemzi egy csomópont centralitását (integráltságát) a hálózaton belül, addig az átlagos fokszám félrevezető lehet globális szinten. Ugyanaz az átlagos fokszám ugyanis előállhat egy olyan hálózat esetén is, amelyben a hálózat csomópontjai nagyjából ugyanannyi kapcsolattal rendelkeznek, de egy olyanban is, ahol a kapcsolatok számának eloszlása lényegesen szélsőségesebb. A hálózat globális struktúráját pontosabban tükrözi az átlagos fokszám helyett az egyedi fokszámok eloszlása. A fokszám-eloszlás lehet szimmetrikushoz közeli (tipikusan Poisson-eloszlás), ahol egy jól jellemezhető átlagos fokszám meghatározható és a csomópontok kapcsolatainak száma ezen

⁶Megjegyzendő, hogy esetünkben a hálózatot irányítatlannak és a kapcsolatokat súlyozatlannak tételezzük fel, ami miatt az \mathbf{A} mátrix szimmetrikus és bináris. A bemutatásra kerülő mutatók a természetesen irányított és súlyozott hálózat esetén is definiálhatók, itt azonban csak a szimmetrikus-bináris esetet mutatjuk be, mivel a további elemzések szempontjából csupán ezeknek van relevanciája. Az empirikus elemzéseknél a súlyozás bevezetése miatt szükséges (minimális) módosításokat ott tárgyaljuk.

átlag körül szóródik kisebb-nagyobb mértékben. Tipikusan ez a helyzet a később részletebben bemutatásra kerülő szabályos és véletlen hálózatokban.⁷ Barabási Albert-László és kollégáinak kutatásai azonban éppen arra mutattak rá, hogy a valós hálózatok rendkívül széles körében (a közlekedési hálózatoktól az élő sejtet átszövő molekuláris hálózatokon át a társadalmi és publikációs hálózatokig) a foksám-eloszlás nem szimmetrikushoz közeli. A hálózat struktúrája nem jellemezhető jól egy átlagos kapcsolati számmal, mivel a tipikus, reprezentatív csomópont létezése helyett a kapcsolatok eloszlása aszimmetrikus: néhány csomópontnak nagyon sok kapcsolata van, míg a hálózat legtöbb tagjának csak néhány kapcsolata. Természetesen ebben az esetben is kiszámítható az átlagos foksám, azonban ez az információ nagy mértékben torzít a hálózat valós struktúráját illetően, hiszen azt néhány (a kapcsolati számot tekintve) fajsúlyos szereplő dominálja, míg a többi csomópont szerepe marginális. Ezzel szemben az átlagos foksám alkalmazása azt sugallja, hogy a hálózati struktúra jellemezhető egy átlagos, reprezentatív csomóponttal. (Barabási, 2002; Barabási és Albert, 1999; Barabási et al., 2000)

A fenti tulajdonság jellemzésére Barabási (2003) a skálafüggetlenség kifejezést használja, utalva arra, hogy a foksám, mint a hálózati struktúra egy jellemzője ezekben az esetekben nem helyezhető el egy előre definiált „skálán”, a hálózati kapcsolatoknak nincsen jól értelmezhető átlagos értéke. Barabási és Albert (1999) azt is megmutatják, hogy a valós hálózatokat leíró foksám-eloszlás sűrűségfüggvénye tipikusan az alábbi formájú hatványfüggvényt követi:

$$z = ks^{-\delta} \quad (3.25)$$

Ez a forma azt fejezi ki, hogy egy adott foksám (s) előfordulásának valószínűsége (vagy relatív gyakorisága – z), annál kisebb, minél nagyobb s értéke. A fenti kifejezésben k és δ konstans paramétereket jelölnek. A δ paraméter értéke kiemelten fontos, mivel ez a paraméter jellemzi a skálafüggetlenség mértékét. Magas δ érték esetén a foksám-eloszlást leíró sűrűségfüggvény görbülete nagyobb, míg alacsonyabb δ érték esetén a görbület kisebb. A függvény görbülete arra utal, hogy az eloszlás mennyire szélsőséges: minél nagyobb a görbület, annál kevesebb a „köztes” foksám, azaz relatíve sok kapcsolattal rendelkező csomópontok száma kevesebb, míg a relatíve kevés kapcsolattal rendelkezők száma egyre több lesz. Szélsőséges esetben a csillag hálózatot kapjuk, ahol egyetlen csomópont rendelkezik $N - 1$ kapcsolattal, a többi $N - 1$ csomópont pedig csupán egy-egy kapcsolattal.

Mindezek alapján tehát a fenti sűrűségfüggvény δ paramétere alkalmas mércéje lehet a skálafüggetlenségnek egy hálózatban. δ kisebb értékeire a foksám-eloszlás egyre egyenletesebbé válik, $\delta = 0$ esetén pedig az eloszlás egyenletes. Természetesen ez az „egyenletesség” nem feltétlenül értendő szó szerint: 0 értéket kaphatunk akkor is, ha a hálózat valamennyi tagjának pontosan azonos számú kapcsolata van, de akkor is, ha a foksám-eloszlás normálisához közeli vagy Poisson-eloszlást követ. Ennek a különbségnek természete-

⁷Megjegyzendő azonban, hogy a véletlen hálózatok esetén a foksám-eloszlás Poisson-eloszlást követ.

tesen nagy jelentősége nincsen, mivel a kapott hálózat mindkét esetben nem skálafüggetlen, a különbség csupán annyi, hogy az ebben az esetben jól definiálható átlagos fokszám körül a fokszám-eloszlásnak mekkora a szóródása.

A (3.25) összefüggésben szereplő δ paraméter – mint a hálózati struktúra egy fontos mutatója – nem számolható ki olyan egyszerű módon, mint például a lokális fokszám vagy az átlagos fokszám. Egy adott hálózat esetén azonban a fokszám-értékek relatív gyakorisága meghatározható, és ezekre a relatív gyakoriság értékekre illeszthető egy, a (3.25) egyenletnek megfelelő függvény. Amennyiben a (3.25) egyenletet loglinearizáljuk, úgy a δ paraméter meghatározása a regressziószámítás standard módszereivel elvégezhető.

A hálózat egészére jellemző további mutató az ún. átlagos elérési út. Definiáljuk a hálózati távolság mátrixot: $\mathbf{D} = [d_{ij}]$ ahol a d_{ij} általános elem az i és j csomópontok hálózatban vett ún. geodetikus távolságát reprezentálja. A geodetikus távolság két csomópont között a hálózatban vett legrövidebb utat jelenti, így a \mathbf{D} mátrix a gráfelméletből ismert legrövidebb-út algoritmusok segítségével könnyen meghatározható, bár a kapcsolati mátrix segítségével zárt forma nem írható fel rá. Minthogy a hálózat nem irányított, így a \mathbf{D} mátrix szimmetrikus lesz, hiszen $d_{ij} = d_{ji}$. Logikus továbbá, hogy egy csomópont önmagától vett távolsága nulla, vagyis $d_{ij} = 0$. Ezek alapján a hálózat tagjai közötti legrövidebb utak átlagaként megadható az átlagos elérési út:

$$ad = \frac{\sum_{i=1}^N \sum_{j=1}^N d_{ij}}{N(N-1)} \quad (3.26)$$

Ez a mutató alkalmas lehet például arra, hogy az információ hálózaton belüli terjedésének valamilyen közelítője legyen. A rövid elérési utak gyors, míg hosszú elérési utak lassú terjedést tesznek lehetővé.

A hálózat globális jellemzője a sűrűség (density) mutatója. A sűrűség egy normalizált mutató, amely azt mutatja meg, hogy a kapcsolatok potenciális számához viszonyítva mennyi kapcsolat van ténylegesen jelen a hálózatban. A sűrűség mutatója ily módon szoros kapcsolatban áll az átlagos fokszámmal. A lehetséges összes kapcsolat száma, miután irányítatlan hálózatról van szó: $N(N-1)/2$. A sűrűség ennek alapján:

$$ds = \frac{\sum_{i=1}^N \sum_{j=1}^N a_{ij}}{N(N-1)} = \frac{as}{N-1} \quad (3.27)$$

Ugyan a sűrűség mutatója normalizált mutató, többen is felhívják a figyelmet arra, hogy a hálózat mérete torzítja a mutatóval kapott eredményeket: nagyobb hálózatok esetén tipikusan kisebb sűrűséget kapunk (lásd például Varga és Parag, 2009). Ennek az az oka, hogy a valós hálózatokban a kapcsolatok száma lassabb ütemben nő, mint a potenciális kapcsolatok száma. N növekedésével ugyanis a lehetséges kapcsolatok száma a (3.27) összefüggés nevezőjében található négyzetes összefüggés szerint növekszik, addig a tényleges kapcsolatok száma nagy valószínűség szerint csupán lineárisan, hiszen az egyes csomópontok

kapacitása korlátozott a tekintetben, hogy kapcsolatokat menedzseljenek. A (3.27) összefüggés második egyenlősége jól ábrázolja ezt a szituációt: az átlagos fokszám (a számláló) tipikusan nem, vagy csak kis mértékben változik a csomópontok számának (a nevező) növekedésével a kapacitáskorlátok miatt. Így tehát a számláló változatlan, a nevező növekszik, a (3.27) egyenlet jobb oldalán álló kifejezés értéke így csökken. A sűrűség ilyen jellegű torzítását elkerülni meglehetősen nehéz, a dolgozatban azzal a „könnyítéssel” élünk, hogy a csomópontok számát adottnak vesszük, így a hálózat méretéből adódó torzítás nem jelent problémát.

A sűrűség, mint globális mutató lokális párjaként adódik a (dolgozatban kiemelt szerepet játszó) klaszterezettség mutatója. Ez a mutató egy igen sokrétű és a hálózat tagjainak lokális környezetét jól leíró mutatószámnak tekinthető. Cowan (2006) definíciója szerint a klaszterezettség annak mutatójaként értelmezhető, hogy egy adott csomópont szomszédjai milyen mértékben szomszédjai egymásnak is. Jelölje Γ_i az i -edik csomópont szomszédságát, vagyis $\Gamma_i = \{j | a_{ij} = 1\}$. Γ_i számosságát a már bevezetett s_i fokszám mutató adja meg: $s_i = |\Gamma_i|$. Jelölje Φ_i azon kapcsolatok halmazát, amelyek az i csomópont szomszédjai, tehát Γ_i elemei között jönnek létre, azaz $\Phi_i = \{(k, l) | k, l \in \Gamma_i\}$, vagy másképpen $\Phi_i = \{(k, l) | a_{ik} = a_{il} = 1\}$. Ekkor a klaszterezettség mutatója az i csomópont vonatkozásában:

$$c_i = \frac{|\Phi_i|}{s_i(s_i - 1)} \quad (3.28)$$

A klaszterezettségnek ez a lokális értelmezése analóg a globális sűrűség mutatójával, tulajdonképpen értelmezhető egyfajta lokális sűrűségként: az adott csomópont környezetének sűrűségeként. Ha c_i értéke magas, akkor az adott csomópont egy sűrű lokális kapcsolatrendszerbe ágyazódik, míg ha c_i értéke alacsony, akkor ez a lokális sűrűség kevésbé jellemző. A lokális sűrűség szerepéről kicsit bővebben is szólnunk majd a következő alpontban.

A klaszterezettség lokális mutatója mellett egy globális mérőszámot is bevezethetünk, ami a tulajdonképpen az egyes csomópontok klaszterezettségének átlagos számát mutatja:

$$ac = \frac{\sum_{i=1}^N c_i}{N} \quad (3.29)$$

A klaszterezettség gráfelméleti megközelítése éppen ezt a globális szintű strukturális jellemzőt definiálja. Luce és Perry (1949) úgy definiálják a globális klaszterezettséget, mint a hálózatban található zárt háromszögek számának az összes lehetséges háromszöghöz viszonyított aránya. Zárt háromszögon itt három egymáshoz közvetlenül kapcsolódó csomópontot értünk. Ez az értelmezés azt tárja fel, hogy a globális klaszterezettség a hálózat lokális kohézióját méri, vagyis hogy a szoros, zárt lokális struktúrák mennyire jellemzőek a hálózatban. A továbbiakban klaszterezettség alatt a (3.29) összefüggés alapján definiált átlagos (globális) klaszterezettséget értjük.

Fontos kiemelni, hogy az átlagos klaszterezettség mutatója nem feltétlenül adja jó közelítést a hálózatban jelen lévő lokális struktúráknak, amennyiben a hálózat sűrűsége növekszik.

Ez a probléma fejlődő, kialakulóban lévő hálózatoknál jelentkezik elsősorban: ilyen esetekben ugyanis a lokális sűrűség, a klaszterezettség növekedése pusztán a globális sűrűség növekedésének a következménye is lehet, így a klaszterezettség növekedése nem feltétlenül utal a lokális kapcsolatok dominanciájának változására.

A hálózati mutatók definiálását követően a következő pontban azokat a konkrét hálózati modelleket mutatjuk be, amelyeket felhasználunk a tudáshálózatok szerepének elemzésénél a korábban kifejtett makrogazdasági általános egyensúlyi modellben.

3.4.2. Hálózati modellek

Az előző pontban bemutatásra kerültek azok a hálózati mutatók, amelyeket a továbbiakban használni fogunk. Ezek a hálózati mutatók alkalmasak arra, hogy a hálózat egészének vagy a hálózat elemeinek egyes jellemzőit számszerű formában reprezentálják. A hálózati mutatók bemutatását azonban azzal kezdtük, hogy ezek bevezetésére azért van szükség, hogy a segítségükkel a hálózati kapcsolatok rendkívül nagy számú kombinációjának halmozában valamiféle rendszert találjunk. A mutatók ismertetése után így szükséges ezeknek a rendszereknek, a lehetséges csoportosításoknak a bemutatása is.

Erre azonban azért is szükség van, mivel a disszertációban a különböző hálózati struktúrák szerepének vizsgálata a célunk. Ehhez pedig a hálózati struktúrák számára bizonyos referencia-pontokat kell kijelölnünk. Ebben az alpontban három ilyen referencia-pontot és ezekhez kapcsolódóan két hálózati modellt mutatunk be, amelyeket a továbbiakban használni fogunk.

3.4.2.1. A Watts-Strogatz hálózati modell

A hálózatelmélet (gráfelmélet) eleinte úgy tekintett a valós hálózatokra, mint véletlen hálózatokra (Barabási, 2002). Ez azt jelenti, hogy a hálózat csomópontjai közötti kapcsolatok minden rendszer nélkül, véletlenszerűen jönnek létre – egészen pontosan az a rendszer, hogy nincsen rendszer. Első ránézésre ez a megállapítás meg is állja a helyét, hiszen a valós hálózatok kapcsolatainak kialakulásában minden bizonnyal nagy mértékű véletlenszerűség van. Ezen a vonalon Erdős és Rényi (1959) munkáját követően a véletlen hálózatoknak széles irodalma alakult ki (Bollobás, 2001).

A véletlen hálózatok létrehozására egy rendkívül egyszerű algoritmus adható. Az N számú csomópont összesen N^2 lehetséges kapcsolatot definiál. Természetesen, ha a csomópontok önmagukkal vett kapcsolatait (hurkokat) nem értelmezzük, úgy csupán $N(N - 1)$ számú potenciális kapcsolat adódik. Haladjunk végig valamennyi lehetséges kapcsolaton (azaz minden (i, j) csomópont-páron) és egy előre definiált p valószínűséggel hozzunk létre kapcsolatot a két csomópont között. Irányítatlan hálózat esetén értelemsszerűen csupán $N^2/2$ vagy $N(N - 1)/2$ potenciális kapcsolat adódik. Az így létrejött hálózatoknak számos érdekes

tulajdonsága van. Szempontunkból talán az a leglényegesebb, hogy az így kialakuló hálózat nem skálafüggetlen: a hálózat jól jellemezhető egy átlagos kapcsolati számmal, ami a hálózat méretének növekedésével pN -hez tart.

Többen is felvetették azonban, hogy a valós hálózatok nem írhatók le a véletlen hálózatok logikájával. Granovetter (1973, 1983) arra hívja fel a figyelmet, hogy a társadalmi hálózatok szorosan integrált lokális csoportok halmazaként jellemezhetőek, ahol a lokális csoportokon belül „erős” kapcsolatok felelősek a kohézióért, ugyanakkor a hálózat egészének nagyon fontos elemei a lokális csoportokat összekötő „gyenge” kapcsolatok. Ez a különbségtétel a társadalmi tőke irodalmában is megjelenik: itt kohéziós (bonding) és áthidaló (bridging) kapcsolatoknak nevezik őket (Callois és Angeon, 2004). A társadalmi tőke irodalmában a két kapcsolat-típus közötti különbségnek lényeges szerepet tulajdonítanak: az erős lokális (bonding) kapcsolatok biztosítják a társadalmi csoportok kohézióját, míg a gyenge, globális (bridging) kapcsolatok teszik lehetővé a csoportok közötti kommunikációt, az újdonságok, az innovációk áramlását, így pedig a lokális csoportok elszigetelődésének, adott esetben önmagába záródásának (lock-in) esélyét csökkentik.


Az Erdős-Rényi féle véletlen hálózatok és a Granovetter-féle lokálisan strukturált hálózatok közötti lényeges különbségek értékeléséhez a korábban bemutatott hálózati mutatók közül kettő alkalmazására van szükség: az átlagos elérési út és az átlagos (globális) klaszterezettség mutatójára. Egy véletlen hálózatban a lokális struktúrák szerepe elhanyagolható, a klaszterezettség alacsony szintű. Ugyanakkor a véletlenszerűség okán a hálózat tagjai közötti elérési utak relatíve rövidek lesznek. A véletlen hálózatokat tehát rövid elérési utak és alacsony átlagos klaszterezettség jellemzi. Ezzel szemben a Granovetter-féle hálózatokat magas klaszterezettség jellemzi, éppen a sűrű lokális kapcsolatok miatt, ugyanakkor az elérési utak rövidek maradnak, mivel a lokális csoportokat összekötő „gyenge” kapcsolatok a hálózat távoli (eltérő lokális csoportokhoz tartozó) tagjai között is gyors kommunikációt biztosítanak.

Ezt a tulajdonságot – a magas szintű klaszterezettség és a rövid elérési utak együttes jelenlétét – a hálózatelmélet és a szociológiai irodalom, az előző fejezetben is kiemelten, kis világnak nevezi. A kis világnak elmélete és a felhozott példák rendkívül kiterjedtek (Buchanan, 2003). Az egyik legismertebb eredménye ennek a kutatási irányvonalnak Travers és Milgram (1969) eredménye. Ők a Harvard egyetem ismeretségi hálózatát vizsgálva jutottak arra a felismerésre, hogy az átlagos elérési út még egy ilyen kiterjedt kapcsolati hálózatban is meglepően rövid, mindössze 5,5 „lépés”. Barabási (2002) megemlíti, hogy a relatíve rövid átlagos távolságok gondolatát korábban Karinthy Frigyes vetette föl egy írásában, ahol meglepően pontosan „előrejelezve” a későbbi tudományos eredményeket, 5 lépéses távolságról ír (Karinthy, 1929).

Alapvető kérdésként merül fel, hogy miként jönnek létre ezek a kis világnak. Elsőként Watts és Strogatz (1998) javasolt egy algoritmust, amivel kis világnak létrehozhatóak. Hálózati modelljünkben a klasszikus véletlen hálózatokkal az ún. szabályos hálózatokat állították szembe. Szabályosnak akkor tekintünk egy hálózatot, ha a csomópontoknak pontosan ugyan-

annyi kapcsolata van, vagy másképpen, ha ezek a kapcsolatok lokálisak. Formálisan ez azt jelenti, hogy ha a csomópontokat sorba rendezzük, akkor egy adott i csomópont kapcsolatai kizárólag a sorban szomszédos elemekkel jönnek létre. A korábbi jelöléseket használva: $\Gamma_i = \{j \mid |i - j| \leq k\}$, ahol k a „szomszédság” kiterjedését adja meg. A kapcsolatok száma minden csomópont esetében $2k$. Egy szabályos hálózat jellemzője a magas klaszterezettség, hiszen a kapcsolatok lokálisan sűrűek. Az átlagos elérési út egy ilyen hálózatban viszonylag hosszú, mivel nincsenek átkötések a lokális csoportok között.

Watts és Strogatz (1998) algoritmus a kis világok tekintetében a következő gondolatra épül. Induljunk ki egy szabályos hálózatból, amelyet egy adott k szomszédság jellemez. Ezt követően valamennyi csomópont valamennyi kapcsolatán lépünk végig, és valamilyen előre adott p valószínűséggel „drótozzuk” át a kapcsolatot. Ez azt jelenti, hogy a „kiindulási” csomópontot meghagyjuk, azonban a „végpontot” megváltoztatjuk úgy, hogy az új partnert véletlenszerűen választjuk ki a többi csomópont közül. Ezzel az eljárással a szabályos hálózatba fokozatosan véletlenszerűséget viszünk. Minél nagyobb p értéke, ez a véletlenszerűség annál nagyobb. $p = 0$ esetén értelemszerűen a kiindulásul szolgáló szabályos hálózatot kapjuk vissza, míg $p = 1$ esetén egy klasszikus véletlen hálózatot kapunk. p értékének növekedésével, azaz ahogy a hálózat egyre véletlenszerűbbé válik, a lokális struktúrák felbomlanak, ugyanakkor az elérési utak rövidülnek, ahogy a hálózat eredetileg távoli tagjai között rövid átkötések (shortcut-ok) jönnek létre. Ezt a folyamatot szemlélteti a 3.1. ábra.⁸



3.1. ábra. Klaszterezettség és átlagos elérési úthossz a Watts-Strogatz modellben

⁸Az ábrán mind a klaszterezettség, mind pedig az átlagos úthossz mutatóját normalizáltuk a (0,1) tartományra. 1-es értéket kapunk, ha az egyes mutatók a maximális értéküket veszik fel, míg 0-át, ha a minimálisat. Jól látható, hogy a maximális érték a szabályos, a minimális pedig a véletlen hálózatok esetén adódik mindkét mutató esetén. Az ábra saját szerkesztés, Cowan (2006) alapján.

Az ábrán jól látszik, hogy a klaszterezettség és az elérési utak változása nem kiegyenlített. p növekedésével az átlagos elérési út már alacsony p értékekre is jelentősen csökken, míg a klaszterezettség csak relatíve magasabb p értékeknél kezd csökkenni. Ennek eredményeképpen nullánál nagyobb, de még relatíve alacsony p értékeknél található egy olyan tartomány, ahol az átlagos elérési úthossz már rövid, a klaszterezettség azonban még magas, vagyis kis világok jönnek létre. Ez egy fontos körülményt mutat: a kis világok létrejöttéhez relatíve kevés szabályos kapcsolat véletlenszerű áthelyezésére van szükség. Ez a néhány véletlenszerű kapcsolat már elegendő átkötést képez a hálózat eredetileg távolabbi tagjai között ahhoz, hogy az elérési utak érzékelhetően csökkenjenek, ugyanakkor a hálózat lokális struktúráit ez még nem bontja meg radikálisan.

A Watts-Strogatz modell tehát egy kézenfekvő eszközt biztosít, amely segítségével (adott hálózati méret és átlagos kapcsolati szám esetén) a hálózatok egy adekvát és egyetlen paraméterrel jól kezelhető tipológiája adható. A p paraméter változása a szabályos és a véletlen hálózatok között képez átmenetet, miközben segítségével a kisvilág-típusú hálózati struktúrák is felfedezhetőek.

3.4.2.2. A Barabási-Albert hálózati modell és kiterjesztése

A Watts-Strogatz hálózati modell széles körben alkalmazott módszertani eszközzé vált az utóbbi időben (lásd pl. Cowan, 2006; Carayol és Roux, 2009). Barabási (2002) azonban rámutat a modell egy komoly hátrányára, mégpedig arra, hogy a modellben a fokszám-eloszlás p értékétől függetlenül Poisson típusú. Az indulási pontként szolgáló szabályos hálózatban a kapcsolatok fokszáma azonos: $2k$. Az algoritmus során azonban a kapcsolatok száma nem változik, így az átlagos fokszám tetszőleges p esetén is $2k$ marad. A hálózat struktúrája továbbra is jellemezhető egy tipikus, reprezentatív csomóponttal, amelynek fokszáma $2k$. Az egyes csomópontoknak ettől több és kevesebb kapcsolata is lehet, azonban a szórás nem nagy, a fokszám-eloszlás $p = 1$ esetén Poisson típusú.

Barabási (2002) éppen arra hívja fel a figyelmet, hogy a valós hálózatok a legtöbb esetben nem jellemezhetőek egy reprezentatív elemmel, így az átlagos fokszámmal. Ezek a hálózatok tipikusan skálafüggetlenek, ami azt jelenti, hogy néhány súlyponti szereplőnek nagyon sok kapcsolata van, míg a többségnek kevesebb. Így az átlagos fokszám relatíve kicsi lesz, miközben a hálózat domináns szereplőinek fokszáma jelentősen magasabb. Ebben az esetben a fokszám-eloszlás nem írható le Poisson eloszlással. Miként Barabási és Albert (1999) kimutatják, a skálafüggetlen hálózatok esetén a fokszám-eloszlás sűrűségfüggvénye a (3.25) hatványfüggvénnyel írható le, sőt rámutatnak arra is, hogy a függvény kitevője (δ), viszonylag stabil értéket mutat különféle valós hálózatokban.

Barabási és Albert (1999) egy algoritmust is javasolnak arra vonatkozóan, hogy miként jönnek létre (állíthatók elő) ezek a skálafüggetlen hálózatok. Az algoritmus két fontos eleme a hálózatok növekedése és az ún. preferenciális kapcsolódás. Előbbi azt jelenti, hogy a hálózathoz egyre újabb és újabb csomópontokat adunk hozzá, míg az utóbbi azt tükrözi, hogy az

újonnan csatlakozó csomópontok úgy alakítják ki új kapcsolataikat, hogy nagyobb valószínűséggel csatlakoznak olyan, már a hálózatban lévő csomópontokhoz, amelyeknek fokszáma magasabb. Ez a két jelenség együttesen vezet ahhoz, hogy a kialakuló hálózatok skálafüggetlenek lesznek. A preferenciális kapcsolódás értelemszerűen egyre nagyobb szerepet biztosít azoknak a csomópontoknak, amelyek több kapcsolattal rendelkeznek. Ugyanakkor a növekedés pusztá ténye is a skálafüggetlenséget erősíti, hiszen legtöbb kapcsolattal éppen a legrégebbi, legidősebb csomópontok fognak rendelkezni (Barabási, 2002; Sebestyén és Parag, 2010).

A fenti modellt többen többféleképpen egészítették ki. A preferenciális kapcsolódás tekintetében a fokszámon kívül más jellemzők is szóba jöhetnek, mint egy csomópont vonzerejét növelő tényezők. Sebestyén és Parag (2010) például megmutatják, hogy a geodetikus távolság is fontos szerepet játszhat a kapcsolatok kialakulása során. Jelen esetben a Barabási-Albert modell egy speciális kiegészítését vezetjük be, amely lehetőséget ad arra, hogy a Watts-Strogatz modellhez hasonlóan egy normált paraméter segítségével a skálafüggetlenség különböző fokait érhük el egy hálózatban.

Az algoritmus alapja a Barabási-Albert modell. Adott egy véletlenszerű kiindulási hálózat csomóponttal és csomópontonként átlagosan kapcsolattal.⁹ Ezt követően $N - M$ lépésben a hálózat méretét N -re növeljük úgy, hogy minden lépésben egy új csomópontot adunk a hálózathoz, amely csomópontok egyenként k kapcsolatot alakítanak ki az adott lépésben. Amiben ez a modell eltér a Barabási-Albert modelltől, az az, hogy az új kapcsolatok kialakítása különböző forgatókönyvek szerint is végbemehet. A különböző forgatókönyveket, akárcsak a Watts-Strogatz modellben, itt is egy paraméter értéke határozza meg, jelölje ezt a paramétert r . Az új kapcsolatok kialakításának algoritmusá így a következőképpen néz ki. Egy adott csomópont új kapcsolata r valószínűséggel a legtöbb kapcsolattal rendelkező lehetséges partnerrel jön létre (Barabási-Albert féle preferenciális kapcsolódás), $1 - r$ valószínűséggel pedig véletlenszerűen a lehetséges partnerek közül valamelyikkel. Így egy olyan hálózati modellt kapunk, amely minden esetben átlagos fokszámú hálózatokat ad eredményül, míg r értékétől függően véletlen vagy centralizált, skálafüggetlen hálózatokat eredményez. Logikus továbbá, hogy r értéke nulla és egy közé kell, hogy essen, a két szélsőséges értéket is megengedve.

A véletlenszerűség az r paraméteren keresztül lép be a modellbe. Ha $r = 1$, akkor egy szélsőségesen centralizált hálózatot kapunk eredményül, ahol a kezdeti hálózat tagjainak rendkívül sok kapcsolata van, míg a többieknek csupán k . Amennyiben $r = 0$, úgy a kapcsolatok teljesen véletlenszerűen alakulnak ki, míg r növekedésével a fokszám egyre nagyobb súlyt kap.

Az algoritmus lépései összefoglalva:


⁹Vegyük észre, hogy a kiindulási hálózat létrehozásánál a kapcsolatok kialakulásának valószínűsége és az átlagos fokszám, mint paraméter felcserélhető: adott M esetén ugyanis az átlagos kapcsolati szám megközelítőleg pM , vagyis $k \approx pM$.

- Létrehozunk egy véletlen hálózatot M számú csomóponttal és k átlagos fokszámmal. Ennek megfelelően a véletlen hálózatot létrehozó belső algoritmus valószínűségi paramétere: $k/(M - 1)$. Ebből következően teljesülnie kell a $k \leq M - 1$ feltételnek.
- Egy új csomópontot definiálunk a hálózatban, amely új csomópont kapcsolatot hoz létre a hálózat már létező csomópontjaival. E kapcsolat létrehozása az alábbi szabály szerint történik:
 - r valószínűséggel a legnagyobb fokszámmal rendelkező potenciális partnerhez kapcsolódik az új csomópont. Potenciális partnerek azok, akikkel még nem jött létre kapcsolat, továbbá kizárjuk a hurkok kialakulását. Ha ez alapján több partner is választható, úgy közülük már véletlenszerűen kerül kiválasztásra a kapcsolódási csomópont.
 - $1-r$ valószínűséggel az új kapcsolat a potenciális partnerek közül véletlenszerűen kiválasztott csomóponttal jön létre.
- A fenti lépést ismételjük addig, amíg a hálózat csomópontjainak száma el nem éri N -et.

Fel kell hívnunk a figyelmet két fontos jelenségre is. Egyfelől a hálózat csak speciális esetben lehet szélsőségesen centralizált, mivel az kezdeti hálózat véletlenszerűsége csak abban az esetben teszi lehetővé a csillag-topológiájú hálózat kialakulását, ha $M = 2$ és $k = 1$. Minden más esetben $r = 1$ esetén egy szorosan kapcsolt központi mag körül jön létre egy kevés kapcsolattal rendelkező periferikus halmaza a csomópontoknak. Másfelől pedig azt is hozzá kell tennünk, hogy $r = 0$ esetén sem kapunk teljes mértékben véletlen hálózatot, mivel a véletlenszerűség maximális súlya ellenére a hálózat növekedésének időbeli dimenziója azt eredményezi, hogy a korábban csatlakozó csomópontok automatikusan több kapcsolattal fognak rendelkezni.

Éppen ezért a hálózat struktúrájának elemzésekor nem feltétlenül jó viszonyítási alap a véletlen hálózat, sokkal inkább az $r = 0$ eset, ugyanúgy, ahogy a Watts-Strogatz modellnél a viszonyítási alap a véletlen hálózat. A 3.2. ábra mutatja a hálózat fokszám-eloszlását leíró hatványfüggvény δ paraméterének abszolútértékét a módosított Barabási-Albert modell r paraméterének függvényében.

Természetesen felvethető, hogy a Watts-Strogatz modell algoritmusának analógiájára egy olyan hálózati modellt alkossunk, amelyben a szélsőségesen skálafüggetlen hálózat jelenti a viszonyítási alapot (vagyis ahol egyetlen csomópontnak $N - 1$ számú kapcsolata van, a többi $N - 1$ csomópontnak pedig egyetlen kapcsolata), majd r valószínűséggel alakítsunk át egy kapcsolatot véletlenszerűen. Ez természetesen lehetővé tenné, hogy a szélsőségesen skálafüggetlen hálózattal szemben, a pólus másik oldalán egy teljesen véletlenszerű hálózat alakuljon ki. Ugyanakkor ez a modell nem biztosítja azt, hogy a létrejövő hálózat több centrális elemmel rendelkezzen, így a Barabásiék által felfedezett és eredeti modelljükben generálható hálózati struktúrák már nem lennének megfigyelhetők.



3.2. ábra. Skálafüggetlenség a módosított Barabási-Albert modellben

Mindezek alapján, a bemutatott két hálózati modell kapcsán fontos megjegyezni, hogy a két modell – bár analógiák találhatóak – nem kapcsolható össze konzisztensen. Ez alatt azt értjük, hogy a Watts-Strogatz modell eredménye $p = 1$ esetén nem egyezik meg a Barabási-Albert modell fent bemutatott módosításának $r = 0$ -ra érvényes esetével. Ennek ellenére valamiféle folytonosságot találhatunk, hiszen a Watts-Strogatz modellben p növekedésével egy szabályos hálózattól egy teljesen véletlenszerű hálózattig jutunk el, míg a módosított Barabási-Albert modellben r növekedésével egy, a véletlen hálózathoz közeli hálózattól egy szélsőségesen skálafüggetlen hálózat felé közelítünk. Ugyanakkor fontos látnunk a két modell közötti alapvető különbséget: a szabályos-véletlen hálózatok nem ugyanazon dimenzióban értelmezettek, mint a kevésbé- és nagyobb mértékben skálafüggetlen hálózatok. Ez éppen abból a tényből következik, ami miatt a skálafüggetlen hálózatok „szükségessé váltak” a hálózatelméletben, nevezetesen, hogy a Watts-Strogatz modell nem alkalmas az ilyen típusú hálózatok leírására. Ebből következően nem állhatja meg a helyét az a feltételezés, hogy p növekedése a Watts-Strogatz modellben tulajdonképpen egyfajta előzménye a módosított Barabási-Albert modell r skálájának.

3.5. Egyensúly a statikus hálózatokkal kibővített modellben

Jelen fejezet második pontjában bemutattam azt a monopolisztikus versenyre épülő általános egyensúlyi modellt, amelyet a továbbiakban a tudáshálózatok szerepének elemzésére használhatunk fel. A negyedik pontban a hálózati struktúrák kérdését vizsgáltam meg alaposabban és bevezettem azt a két hálózati modellt, amelyek a tudáshálózatok alkalmas reprezentációjaként a továbbiakban beépítésre kerülnek az általános egyensúlyi modellbe.

E modellek segítségével lehetőség nyílik arra, hogy a tudáshálózatok struktúrájának a gazdaság egyensúlyi helyzetére gyakorolt hatását vizsgáljuk.

Ahogy azt már a 3.2. alfejezetben is kiemeltük, amennyiben a hálózati kapcsolatok szerepét vizsgáljuk, úgy a vállalatok homogenitására vonatkozó feltevést fel kell adnunk. Ez azt is eredményezi, hogy a korábban bevezetett modell analitikus megoldása már nem lehetséges, numerikus módszerekhez kell nyúlnunk. A numerikus módszerek azonban szükségessé teszik, hogy az elemzés kereteit valamiképpen szűkítsük, így az elemzés szükségszerűen parciálissá válik, ami főként abban jelentkezik, hogy a paraméterek értékeit specifikálnunk kell. Ennek fényében most röviden áttekintjük a modell megoldásának algoritmusát.

- Az algoritmus első lépéseként a 3.4.2. pontban bemutatott két hálózati modell valamelyikével előállítjuk az \mathbf{A} kapcsolati mátrixot.
- Az \mathbf{A} kapcsolati mátrix és az exogén változóként adott \mathbf{k} tudás-vektor a (3.5) tudás-aggregátoron keresztül meghatározza a vállalatok számára hozzáférhető tudás mennyiségét, K_i -t, minden i vállalat esetén.
- Ezt követően a gazdaság általános egyensúlyi állapotát határozzuk meg, vagyis azt a w bérszintet és \mathbf{p} árvektort, amelyre mind a termékpiacokon, mind pedig a munkapiacon egyensúly van. Az egyensúly meghatározásának menete a következő:
 - Kiválasztunk egy induló bérszintet. Közelítő választásként adódik a szimmetrikus esetben levezetett egyensúlyi bér, amelyet a (3.21') összefüggés ad meg.
 - A kiválasztott bérszint és a többi paraméter alapján megoldjuk az egyensúlyi árakat meghatározó (3.12') egyenletrendszer, így megkapjuk az adott bérszint esetén a termékpiacok egyensúlyát biztosító árvektort.
 - A kapott árvektort felhasználva a (3.8) keresleti függvények segítségével megadható az egyes termékekből keresett és a piaci egyensúly miatt egyben termelt mennyiség, azaz a vállalati kibocsátások \mathbf{y} vektora.
 - A vállalatok kibocsátása a (3.3) termelési függvények alapján meghatározza a vállalatok által felhasznált munkamennyiséget, amit a munkafelhasználás \mathbf{L} vektora ad meg.
 - A munkafelhasználás vektora lehetővé teszi, hogy ellenőrizzük a munkapiaci egyensúly feltételének teljesülését. Amennyiben a munkapiaci egyensúly nem teljesül, új bérszintet választunk és ennek segítségével ismét elvégezzük a fenti iterációt, meghatározzuk az árvektort, majd ebből a munka-felhasználási vektort. Munkapiaci túlkereslet esetén a bérszintet értelemszerűen növelni, míg túlkínálat esetén csökkenteni kell, hogy az egyensúlyi helyzet irányába haladjunk.
- A fenti folyamat iterációjával végül eljutunk ahhoz a bérszinthez, amelyre a munkapiac és valamennyi termékpiac is egyensúlyba kerül.

A fenti algoritmus során megoldandó egyenletrendszerek nemlineárisak, így minden esetben fontossá válik az egyes változók megfelelő kezdő értékének meghatározása. Ezeket a kezdeti értékeket alkalmas módon a 3.3. alfejezetben bemutatott speciális, szimmetrikus vállalatokra felírt modell összefüggései adják meg.

Összefoglalásképpen felsoroljuk a modell jelöléseit, paramétereit, exogén és endogén változót.

A paraméterek:

- α , a munka parciális termelési rugalmassága ($0 < \alpha < 1$)
- σ , a vállalatok által termelt termék-variánsok közötti helyettesíthetőség paramétere ($0 < \sigma < 1$)
- θ , a tudás-áramlás spillover paramétere ($0 < \theta < 1$)
- ρ , az egyes vállalatok tudása közötti helyettesíthetőség paramétere ($0 < \rho < 1$)
- N , a vállalatok és ezáltal a tudás-hálózat csomópontjainak száma ($N \geq 2$)
- R , a tudás-hálózatok átlagos fokszáma ($1 \leq R \ll N$)
- p vagy r , a hálózati modell valószínűségi paramétere ($\leq p \leq 1$ és $\leq r \leq 1$)
- I , az összes nominális jövedelem vagy pénzmennyiség ($I > 0$)
- \bar{L} , a munkakínálat ($\bar{L} > 0$)

Az exogén változók

- \mathbf{A} , a hálózatot leíró kapcsolati mátrix ($a_{ij} \in (0, 1)$)
- \mathbf{k} , a vállalatok autonóm tudás-vektora ($k_i > 0$)
- \mathbf{K} , a vállalatok által hozzáférhető tudás vektora (\mathbf{A} és \mathbf{k} által meghatározott)

Endogén változók

- w , a bérszint
- \mathbf{p} , a vállalatok árvektora
- \mathbf{y} , a vállalatok kibocsátás-vektora
- \mathbf{L} , a munkafelhasználás vektora.

A modell fenti endogén változói alapján az összes kibocsátást és az árszínvonalat definiáljuk, mint származtatott endogén változókat. A gazdaság összes kibocsátása egyszerűen az egyedi kibocsátások összegeként adódik:

$$Y = \sum_{i=1}^N y_i \quad (3.30)$$

Az aggregált árszínvonal pedig az egyedi árszintek súlyozott átlagaként, ahol a súly az adott vállalat kibocsátásának összes kibocsátáson belül vett aránya.

$$P = \sum_{i=1}^N \frac{y_i}{Y} p_i = \frac{1}{Y} \sum_{i=1}^N p_i y_i \quad (3.31)$$

A fenti kifejezés eleget tesz annak a feltételnek is, hogy a makroszintű reálkibocsátás (Y) a nominális kibocsátás és az árszínvonal hányadosaként adódik.

4. fejezet

Modell-szimulációk és analízis

Az előző fejezetben bemutatott egy egyszerű általános egyensúlyi modellt, amelybe explicit módon beépítettem a tudáshálózatokat. A modell bemutatása után ebben a fejezetben a főbb implikációk vizsgálatára kerül sor. Tekintve, hogy a modell megoldása analitikusan nem lehetséges, szimulációs technikát alkalmazunk a vizsgálatok során. A szimulációk segítségével lehetőség nyílik arra, hogy a modell működését különböző paraméterkombinációk mellett vizsgáljuk meg. Az analitikussal szemben a numerikus módszerek alkalmazása ugyanakkor azt is szükségessé teszi, hogy a modell paramétereinek konkrét értékeket válasszunk meg. A következő alfejezetben a rögzített paraméterek értékét és az értékválasztás indoklását adjuk meg.

4.1. Paraméterek meghatározása

A modell paramétereit több csoportra bontjuk, attól függően, hogy a paraméterek értékét a fejezetben bemutatott szimulációk során meddig rögzítjük. Így adódnak olyan paraméterek, amelyek mindvégig rögzítettek maradnak, olyan paraméterek, amelyek csak az első, benchmarkként szolgáló futtatások erejéig rögzítünk, és olyan paraméterek is, amelyeket több futtatás során is rögzítettnek hagyunk. Ebben az alfejezetben valamennyi, a továbbiakban így vagy úgy rögzítésre kerülő paraméterrel foglalkozunk, a szimulációk bemutatása során pedig mindig kiemeljük, hogy mely paraméter értékeit rögzítjük az adott vizsgálat során.

A tartósan rögzítendő paraméterek kiválasztásánál két szempont vehető figyelembe. Az egyik, hogy olyan paramétert rögzítsünk tartósan, amelyek változása a modell működésére és a kapott eredményekre nem gyakorol hatást, a másik, pedig, hogy vizsgáltunk szempontjából a paraméter változása ne legyen meghatározó. Ezekon kívül egy harmadik szempont is szóba jöhet, ami arra vonatkozik, hogy olyan paraméter értékét érdemes tartósan rögzíteni, amelyek értékére rendelkezésre állnak akár empirikus, akár elméleti alapokon álló információk. Jelen pontban végső soron mindhárom szempontot figyelembe véve határozzuk meg a tartósan rögzítésre kerülő paraméterek körét.

Az első szempont szerint talán a legkézenfekvőbb jelölt a tartós rögzítésre a nominális jövedelem paramétere, I . Ennek a korábban már említett dichotómia az oka. Bár a nem-specifikus modell működéséről egyelőre nem tudunk biztosat, a homogén szereplőkre vonatkozó speciális eset azt sugallja, hogy ez a paraméter nem játszik lényeges szerepet a reálváltozók meghatározódásában, továbbá a nominális változók meghatározásában is a klasszikus tételek érvényesülnek. Ezek alapján I értékét több futtatás során is rögzítjük, ezekben az esetekben $I = 100$ -zal dolgozunk.

Hasonló módon rögzítjük a munkakínálat nagyságát is. Bár ez a változó már szerepel a reálkibocsátás meghatározódásában a homogén vállalatokat tartalmazó speciális esetnél is, szerepe azonban triviálisnak tekinthető. A numerikus szimulációk során $\bar{L} = 100$ -zal dolgozunk.

A fejezetben mindvégig rögzítésre kerül a vállalatok és a hálózat mérete, N . Ennek praktikus okai vannak, ugyanis a cél a hálózati struktúra szerepének vizsgálata, amely adott N esetén is lehetséges. Ugyanakkor ezzel az eljárással kiküszöböljük a hálózat méretének változásából fakadó torzításokat és a fókusz valóban a hálózati struktúrán marad. N értékét 50-re állítjuk be a szimulációk során. A tudás-hálózatot meghatározó paraméterek közül tartósan rögzítésre kerül R , a kapcsolatok átlagos száma is. Minthogy N is rögzített, így a hálózatok sűrűsége is adott. Ennek az az egyik fontos következménye, hogy a klaszterezettség mutatója alkalmas mércéje a lokális struktúrák szerepének, mivel a sűrűség változásából fakadó torzításokat így kiküszöböljük. Ezzel szemben p vagy r értékét, azaz a hálózati modellek valószínűségi paramétereit nem rögzítjük, mivel éppen ezek változása teszi lehetővé különböző hálózati struktúrák vizsgálatát.

Az első, benchmarkként kezelt futtatásokon kívül nem rögzítjük a tudás-aggregátor két paraméterét, θ -t és ρ -t. Ennek az az egyszerű oka van, hogy ezek a paraméterek a tudáshálózatok kialakulásánál és a tudás-áramlás szempontjából jelentőséggel bírnak, az elemzés hozzáadott értékét képviselik, így megfelelnek a korábban említett második szempontunknak.

Rögzítésre kerül végül a makromodell két paramétere, α és σ . Itt két szempont is döntő. Egyfelől ezek a paraméterek a makromodell részét képezik, így a tudás-áramlással és a tudáshálózatokkal nem közvetlen a kapcsolatuk. Másfelől viszont ezek olyan paraméterek, amelyek a makroökonómiai szakirodalom alapján könnyen meghatározhatóak, sőt, releváns empirikus bázison a meghatározott értékek védhetők is. E két paraméter ugyanis a széles körben elterjedt és alkalmazott DSGE modellek (dinamikus sztochasztikus általános egyensúlyi modellek) szerves részét jelenti.

Egyrészt ezek a modellek is tartalmaznak termelési függvényt, így a munka parciális termelési rugalmasságát is, másrészt pedig tipikusan monopolisztikus versenyt feltételeznek, ami a termékvariánsok közötti helyettesítés rugalmasságának explicit figyelembe vételét igényli. Ami miatt a paraméter-értékek meghatározásánál ezek a modellek számunkra hasznosak, az az a tény, hogy a DSGE modellek gazdaságpolitika alkalmazhatósága ezek empirikus becslését és/vagy kalibrálását teszi szükségessé. Az alkalmazott DSGE modellek tehát

e paraméterértékekre valamilyen empirikusan alátámasztható értékhalmozat szolgáltatnak. Éppen ezért a két szóban forgó paraméter értékének rögzítése során alkalmazott DSGE modellekhez nyúlunk és az ott használt paraméterértékek alapján képezünk egy átlagos értéket.

Elsőként az α paraméter értékét vizsgáljuk. Smets és Wouters (2007) alapvető referenciaként szolgáló, az Amerikai Egyesült Államok adataira megbecsült modelljében a munka parciális termelési rugalmasságának értékét 0,81-nek veszik. Hozzá kell azonban tenni, hogy ez az érték nem becsült, hanem a tőkejövedelmek összjövedelmen belüli arányának segítségével kalibrált érték. Ratto és szerzőtársai (2009) hasonló modellje az euróövezet adataira (QUEST III) szintén egy kalibrált paraméter-értéket használ, melynek értéke 0,52. Dib (2001) és Mendoza (1991) egyaránt kanadai adatokon becsült DSGE modellt mutatnak be, amelyben a munka parciális termelési rugalmassága rendre 0,67 és 0,68. A Bank of England negyedéves modellje (BEQM) α értékét 0,69-nek veszi (Harrison és szerzőtársai, 2005), míg a svéd jegybank 0,71-es értékkel számol (Adolfson és szerzőtársai, 2007).

Természetesen hazai alkalmazásokból is meríthetünk. Jakab és Világi (2008) Magyar Nemzeti Bank által használt DSGE modellben CES típusú termelési függvényt használnak, itt a munkatényező részesedési paramétere 0,83. Ez bizonyos megkötések mellett (a tőke és a munka közötti helyettesítés rugalmassága egységnyi) megfeleltethető az általunk használt parciális termelési rugalmasságnak. Baksa és szerzőtársai (2009) a Magyar Köztársaság Költségvetési Tanácsa számára készített modellben a munka parciális termelési rugalmasságát kalibrálják, az általuk használt érték 0,72.

A σ paraméter a monopolisztikusan versenyző vállalatok által előállított termékvariánsok közötti helyettesítési rugalmasságot méri. E paraméter is fontos eleme az alkalmazott DSGE modelleknek, mivel ezek döntő többsége a monopolisztikus verseny feltevésével él. E paraméter kapcsán két probléma merül fel. Ez egyik, hogy a modellek alapvetően két típusra oszthatók: egyes modellekben a monopolisztikusan versenyző vállalatok a végső fogyasztási cikkek előállítói, míg más modellekben a közbülső javakat állítják elő monopolisztikusan versenyző vállalatok, majd ezeket a javakat egy tökéletesen versenyző szektor homogén végső felhasználású javakká „csomagolja”. Ennek megfelelően a monopolisztikus verseny keretében előállított termékvariánsok helyettesítési paramétere nem feltétlenül ugyanazt a kategóriát jelenti az egyes modellekben. Barro és Sala-i-Martin (1995) azonban megmutatják, hogy a két megközelítés között a modellek következtetéseit tekintve lényeges eltérés nincsen, így a két modell-típus által használt σ paramétereket összehasonlíthatóaknak vesszük.

A másik probléma a paraméterek meghatározása során adódik. Amíg az α paraméter esetén a kalibrálás vagy akár az ökonometriai becslés egyszerűen kivitelezhető,¹ addig a helyettesítési paraméter az adatsorokból közvetlenül nem, csak közvetve határozható meg. Ez a probléma világosan tükröződik a hivatkozott DSGE modellekben. A legtöbb esetben a

¹Ez abból ered, hogy a jövedelem-eloszlás klasszikus határtermelékenységi elmélete szerint a paraméter a munkajövedelmek összjövedelmen belüli arányaként is értelmezhető.

helyettesítési paraméter értékét egyszerűen átveszik más modellekből, és se nem kalibrálják, se nem becslik őket. Úgy tűnik, hogy e hivatkozások eredője Rotemberg és Woodford (1995) tanulmánya, ahol a paraméter értékét aszerint állítják be, hogy az egyensúlyi állapotban adódó árrés (price markup) a benchmarknak számító 1,2-es értéket vegye fel. Ennek megfelelően a σ paraméter értéke 0,83. Ezt az értéket veszi át Jakab és Világi (2008), Dib (2001), valamint a FED SIGMA modellje is (Erceg és szerzőtársai, 2006). A paraméter kalibrált értékével dolgozik Ratto et al. (2009) QUEST III modellje, itt a paraméter értéke 0,9, akárcsak Smets és Wouters (2007) modelljében. Ez utóbbinál meg kell azonban jegyeznünk, hogy a modell nem az általunk, valamint a többi referencia-modellben is használt Dixit-Stiglitz aggregátort alkalmazza, hanem az ún. Kimball-aggregátort, ami a helyettesítési rugalmasság változását lehetővé teszi (Kimball, 1995). Ha azonban feltételezzük a rugalmasság konstans voltát, akkor σ értékére 0,9-et kapunk. Kalibrált értékeket közöl Rotemberg és Woodford (1998), Amato és Laubach (2003) valamint Harrison és szerzőtársai (2005), ezek rendre 0,873, 0,81 és 0,91. Az Európai Központi Bank által használt DSGE modell σ értéke 0,74 (Christoffel és szerzőtársai 2008).

Látható, hogy a paraméter meghatározása során általánosnak tekinthető a kalibrálás vagy egy specifikus érték átvétele más forrásokból. Néhány modellben azonban a paraméter közvetlenül becsült. Erre úgy van lehetőség, hogy bizonyos feltételek teljesülése esetén a helyettesítési paraméter (a helyettesítési rugalmasságon keresztül) közvetlenül meghatározza a monopolisztikusan versenyző vállalatok árrését. Így az árrés értékéből vissza tudunk következtetni a helyettesítési paraméter értékére. A svéd jegybank DSGE modellje ezt az eljárást használja. Az árrés egyensúlyi értékére 1,22-es értéket kapnak, amiből visszszámolva a helyettesítési paramétert 0,82 adódik. Látható, hogy ez az érték nagyságrendileg megfelel a kalibrált modellek által használt értéknek.

Szerző	Ország	α	σ
Smets-Wouters (2007)	USA	0,81	0,9
Ratto et al. (2009)	Eurozóna	0,52	0,9
Dib (2001)	Kanada	0,67	0,83
Mendoza (1991)	Kanada	0,68	-
Harrison et al. (2005)	Anglia	0,69	0,91
Adolfson et al. (2007)	Svédország	0,71	0,82
Jakab-Világi (2008)	Magyarország	0,83	0,83
Baksa et al. (2009)	Magyarország	0,72	-
Erceg et al. (2006)	USA	-	0,83
Christoffel et al. (2008)	Eurozóna	-	0,74
<i>Átlag</i>		<i>0,70</i>	<i>0,85</i>

4.1. táblázat. Alkalmazott DSGE modellek strukturális paraméterei

A 4.1. táblázat összefoglalja az előbbieken felsorolt modellek vonatkozó értékeit. A hiányosságok arra utalnak, hogy egyes modelleknél az adott paraméterre vonatkozó értékeket (vagy azokra vonatkozóan valamilyen támpontot) a modell leírása nem tartalmazza. Ez alapján az összevetés alapján azt mondhatjuk, hogy a DSGE modellek irodalmában az általunk használt két paraméterre jól meghatározott, különösebben nagy szóródást nem mutó érté-

kek találhatóak. A továbbiakban a modell α és σ paramétereit a hivatkozott modellekben használt értékek átlaga alapján részben rögzítjük, rendre 0,7-es és 0,85-ös értékkel.


A hálózatokkal kibővített általános egyensúlyi modell két exogén változója marad még kérdéses, nevezetesen az **A** kapcsolati mátrix és a vállalatok egyedi tudásszintjeit tükröző **k** tudásvektor. A kapcsolati mátrixot a hálózati paraméterek (a csomópontok száma, az átlagos fokszám valamint a hálózati modell paraméterei) egyértelműen meghatározzák. A tudásvektor kapcsán a 4.2. és 4.3. alfejezetben azzal a feltevessel élünk, hogy a vektor értékei egységnyiek, azaz a vállalatok között nincsen különbség a tudásszintek tekintetében.² Ezt a feltételezést azonban a 4.4. és 4.5 alfejezetekben feloldjuk.

Egy fontos megjegyzés szükséges itt a modell két helyettesítési paramétere vonatkozásában. Természetesen felvethető, hogy a két helyettesítési paraméter értéke meg kell, hogy egyezzen, hiszen minél kevésbé helyettesíthetőek egymással a tudás-bázisok, annál kevésbé lesznek az adott tudás-bázison előállított termékek is helyettesítők. Ugyanakkor elképzelhető olyan eset is, amikor eltérő tudás-bázisokon azonos termékek kerülnek előállításra. Egy kézenfekvő példa lehet a hagyományos képcsöves és az LCD technológiával készült televíziók esete, de akár a hagyományos fosszilis üzemanyaggal és az üzemanyag-cellás technológiával működő gépkocsik esete is felhozható, bár ez utóbbi egyelőre inkább fejlesztési, mint gyártási fázisban van. Ugyanakkor ellentétes példa is hozható: ugyanazon a tudás-bázison, tehát közel tökéletes helyettesítés mellett lényegesen eltérő igényeket kielégítő termékeket is elő lehet állítani. Ami látható, hogy a két helyettesítési paraméter közötti lényegi különbség abból fakad, hogy a tudás-aggregátor ρ paramétere a termelés oldalán jelentkező viszonyokat reprezentálja, addig a hasznossági függvény σ paramétere a fogyasztói preferenciákat írja le. Természetesen a kettő közötti lényeges kapcsolat sem elhanyagolható már csak azért sem, mivel az itt figyelmen kívül hagyott dinamikus elemek fontos konvergenciát implikálnak a két paraméter tekintetében: akár a televíziók példája esetén is könnyen belátható, hogy a domináns technológiák fokozatos elterjedése a tudás-bázisokat jellemzően közelíti egymáshoz, így a helyettesíthetőség növekszik. Ugyanakkor a technológiai fejlődés folyamatossága azt is biztosítja, hogy a domináns technológiák kialakulása során, azokkal párhuzamosan már megjelennek az eltérő tudásbázison működő helyettesítő („niche”) technológiák. További fontos pont az is, hogy modellünkben a tudást széles körűen definiáltuk, azaz abba beletartozik a konkrét technológiai tudáson kívül a munkaszervezéssel, menedzsmenttel kapcsolatos rutinok, eljárások összessége is csakúgy, mint olyan „soft” tényezők, mint a vállalati kultúra vagy emberi erőforrás menedzsment. Nagyon fontos éppen ezért kiemelnünk, hogy a tudás e szélesebb körű értelmezése lehetővé, sőt, szükségessé is teszi a két helyettesítési paraméter egymástól történő elválasztását, hiszen az alkalmazott fizikai technológia hasonlósága mellett ezek a munkaszervezéssel kapcsolatos vállalat-specifikus tudáselemek biztosíthatják a diverzitást a tudásbázis különböző területei között.

²Ez természetesen nem azt jelenti, hogy a vállalatok homogének lennének. Arról van szó, hogy a vállalatok saját technológiai területükön azonos mélységű szakértelemmel bírnak.

4.2. Kis világok és általános egyensúly

Első lépésben a Watts-Strogatz modell segítségével vizsgáljuk a hálózati struktúra gazdasági tevékenységre gyakorolt hatását. A fentieknek megfelelően a következő numerikus szimulációt végezzük el. A Watts-Strogatz modell p paraméterének különböző értékei mellett kialakuló hálózati struktúrán elvégezzük a 3.5. alfejezetben levezetett egyensúly-meghatározó algoritmust. A szimulációk során a modell többi paraméterét rögzítjük, vagyis az egyedüli változónak a hálózati struktúrát leíró p paraméter. Az előző pontban elmondottak alapján a hálózat elemeinek száma 50, az átlagos kapcsolati szám 6, α és σ értékét 0,7-nek és 0,85-nak állítjuk be. A tudás-aggregátor paramétereire ad-hoc értéként ρ és θ értékeket határozunk meg. E paraméterek változásának hatását később részletesebben is megvizsgáljuk. Az így beállított paraméter-értékek mellett tehát adódik egy hálózat, majd e hálózati struktúra mellett kiszámítjuk az általános egyensúlyra jellemző makrogazdasági output-változókat. A vizsgálat során valamennyi p értékre 1.000-szer futtattuk le a szimulációt, amire azért van szükség, mivel a Watts-Strogatz algoritmus sztochasztikus elemet is tartalmaz, így ugyanarra a p értékre különböző futtatások során némileg eltérő hálózati struktúra, így potenciálisan eltérő aggregált gazdasági teljesítmény adódhat. A p paraméter értékét 0 és 1 között 0,01-os lépésközzel változtattuk.



4.1. ábra. Az aggregált kibocsátás alakulása a Watts-Strogatz modell p paraméterének függvényében

A 4.1. ábrán a reálkibocsátás alakulása követhető nyomon p függvényében. A vastag vonal az összes kibocsátásra kapott futtatásonkénti eredmények átlagát mutatja, míg a szaggatott vonalak az átlag körüli szórás értékét reprezentálják. A függőleges tengelyen a $p = 0$ esethez képest vett értéket tüntettük fel. Az ábráról jól látható a p paraméter és a kibocsátás közötti pozitív irányú összefüggés. Ez azt jelenti, hogy amennyiben az alapul szolgáló tudás-hálózat a szabályos, lokálisan strukturált formától a véletlenszerű felé halad, úgy a


hálózatra „épülő” gazdaság kibocsátása emelkedik. A stabilan emelkedő tendencia $p = 0,6$ körül megtörik, lelassul, míg p magas értékeire számottevő javulás már nem érzékelhető.

Nagyon fontos kiemelnünk, hogy az ábrán látható eredmények kizárólagosan a hálózat struktúrájának változásából fakadnak. Ha ugyanis visszatekintünk az előző fejezet elején bevezetett (3.3) termelési függvényre és (3.5) tudás-aggregátorra, akkor könnyen beláthatjuk, hogy a vállalatok által kialakított kapcsolatok száma önmagában pozitív hatással van a kibocsátásra. Ha tehát az átlagos foksám (rögzített N mellett a sűrűség) növekszik, akkor az egyedi termelési függvények K_i technológiai paramétereinek átlagos értéke is növekszik, ami az aggregált kibocsátás szintjét értelemszerűen növeli. Az alkalmazott két hálózati modell jelentősége éppen abban rejlik, hogy minden esetben azonos átlagos kapcsolati számot adnak eredményül. A Watts-Strogatz modellben a csomópontok száma konstans, és a kapcsolatok száma is konstans, hiszen az algoritmus során csupán a meglévő kapcsolatok áthelyezését végezzük el, de kapcsolatokat nem hozunk létre illetve nem is szüntetünk meg. Így tehát a fenti ábrán látható hatás nem fakadhat abból a triviális megállapításból, hogy több kapcsolat több hozzáférhető tudást és ezáltal magasabb termelékenységet és kibocsátást jelent. Eredményünk tehát azt bizonyítja, hogy a hálózati struktúrának magának, vagyis a kapcsolatok egymáshoz képest vett elhelyezkedésének is külön szerepe van a gazdasági teljesítmény alakulásában.

A hálózati struktúra szerepének fent bemutatott relevanciáján túl a kapott eredmények érdekes következtetéseket implikálnak a kis világok, mint speciális hálózati struktúrák szempontjából. A hálózati modelleket bemutató fejezetpontban azt láttuk, hogy a Watts-Strogatz modellben p relatíve alacsony értékeire alakulnak ki kis világok, magas klaszterezettséggel és rövid átlagos elérési úthosszal. Ezzel szemben a hálózatra épülő gazdasági tevékenység figyelembevétele azt mutatja, hogy a legmagasabb aggregált kibocsátást akkor kapjuk, ha a gazdasági tevékenység alapjául szolgáló tudás-hálózatok a lehető legvéletlenszerűbbek. Ugyanakkor érdemes megfigyelni egy érdekes tendenciát: a kibocsátás alakulása p függvényében nagyjából lineáris növekedést mutat $p = 0,5$ -ig, majd a kibocsátás növekedése egyre kisebb ütemű, egyfajta csökkenő hozadék érvényesül. Ha visszatekintünk a klaszterezettséget és az átlagos úthosszt bemutató 3.1. ábrára, akkor azt látjuk, hogy körülbelül ez az a pont, ahol mind a klaszterezettség, mind pedig az átlagos elérési út eléri a minimális értékét. Ez azt a következtetést implikálja, hogy az átlagos elérési út és a klaszterezettség csökkenése, illetve ezzel együtt a véletlenszerűség növekedése ugyan fontos tényező az aggregált kibocsátás alakulásában, a véletlenszerűség növekedésének „határhozadéka” addig magas, amíg az alapul szolgáló hálózat kis világnak tekinthető. Egy ilyen hálózatban egy-egy újabb áthidaló kapcsolat létrejötte a lokális csoportok között nagyobb mértékben képes növelni a gazdaság teljesítményét, mint egy ugyanilyen addicionális áthidaló kapcsolat abban az esetben, ha a hálózat már nem rendelkezik a kis világra jellemző karakterisztikákkal.

Vizsgálhatjuk az árszínvonal alakulását is, ez azonban triviálisnak tűnik, hiszen adott nominális kibocsátás (pénzmenyiség) mellett a magasabb aggregált kibocsátáshoz alacsonyabb

árszínvonalnak kell társulnia. A szimulációs eredmények ezt megerősítik: p növekedésével az árszínvonal csökken. Ettől érdekesebb kérdés annak vizsgálata, hogy az egyedi vállalatok kibocsátása mennyire szóródik a különböző hálózati struktúrák esetén.



4.2. ábra. A vállalatok egyedi kibocsátási szintjeinek relatív szórása a Watts-Strogatz modell p paraméterének függvényében

A 4.2. ábra mutatja a vállalatok egyedi kibocsátásainak relatív szórását a p paraméter függvényében.³ Azt látjuk, hogy a vállalatok kibocsátása nem mutat számottevő szóródást, a relatív szórás értéke átlagosan legfeljebb 3,5%. A szórás azonban növekvő tendenciát mutat: minél magasabb p , annál nagyobb a különbség az egyes vállalatok kibocsátása között. Ugyanakkor az aggregált kibocsátás kapcsán elmondottak érvényesek itt is: a szóródás mindaddig növekszik, amíg a klaszterezettség és az átlagos elérési út csökken. A vállalatok kibocsátásának különbségével mért heterogenitás tehát szintén összefüggésben van a kis világ struktúrával: mindaddig, amíg a kis világ struktúra jellemző a hálózatra, újabb áthidaló kapcsolatok létrejötte a vállalatok közötti különbségeket növeli, ugyanakkor abban az esetben, amikor az újabb áthidaló kapcsolatok létrejötte a klaszterezettséget és az átlagos elérési utat már nem képes érdemben csökkenteni, a vállalatok közötti különbségek már nem nőnek tovább.


A fenti elemzés segítségével sikerült rávilágítanunk arra, hogy a gazdasági tevékenység alapjául szolgáló tudáshálózatok struktúrája hatással van az aggregált kibocsátásra. Azt láttuk, hogy a véletlenszerűség és a kibocsátás között pozitív kapcsolat fedezhető fel, ugyanakkor a kis világokra jellemző hálózat struktúra másodlagos szerepe is megfigyelhető. Együttal egy további érdekes tendencia is feltárható: a magasabb kibocsátással párosuló véletlen

³Ez az érték nem azonos a 4.1. ábra (szaggatott vonallal jelölt) szóródási tartományával. Ott az adott p értékek mellett lefuttatott 1.000 szimuláció során kapott aggregált kibocsátási értékek (Y) szórását tüntettük fel, míg a 4.2. ábra a szimulációk során kapott egyedi vállalati kibocsátások (y_i) értékének átlagos szórását mutatja adott p értékek mellett. A szaggatott vonal ebben az esetben a relatív szórás szórása.

hálózatok esetében a vállalatok egyedi teljesítményei átlagosan nagyobb szóródást mutatnak. Vagyis egyfajta trade-off kapcsolatot látunk a gazdaság teljesítménye és a szereplők (vállalatok) homogenitása között.⁴

Fontos azonban megvizsgálunk azt is, hogy a kapott képet mennyiben árnyalja az, hogyha más paraméter-értékekre is elvégezzük az elemzéseket. Az elemzés e kibővítésének első lépéseként azt vizsgáljuk meg, hogy a tudás-aggregátor két paraméterének, ρ -nak és θ -nak a változása miként befolyásolja a kapott eredményeket. Ebben a szakaszban a következő stratégiát követjük. Először θ értékét továbbra is változatlanul véve különböző ρ értékekre végezzük el a szimulációt, majd ρ értékét rögzítve különböző θ értékekre végzünk hasonló elemzést, miközben p a már megszokott módon változik. Ennek az eljárásnak az előnye, hogy egy kétdimenziós paraméter-teret kapunk (ρ és p , illetve θ és p), amelyben színskálát alkalmazva az eredményváltozó értéke a két változó paraméter függvényében megmutatható.

Elsőként tehát a paraméterek közül p és ρ kivételével valamennyit a már ismertetett értékek mellett rögzítjük. p értéke a $(0; 1)$ intervallumon változik, ρ értékét pedig a $(0, 4; 0, 6)$ intervallumra szűkítettük.⁵ Az α és σ paraméterek értéke a korábban ismertetett szinteken kerül rögzítésre, θ értékét pedig $0,8$ -nek állítottuk be. Minden paraméter-kombinációra 20 futtatást végeztem el, majd ezek eredményeit átlagoltam.



4.3. ábra. A modell p és ρ paramétereinek hatása az aggregált kibocsátásra a Watts-Strogatz modellben

A 4.3. ábra mutatja a kapott eredményeket a kibocsátásra. A sötét árnyalatok az alacsonyabb, a világos árnyalatok a magasabb kibocsátás-értékeket jelenítik meg. Fontos meg-

⁴Homogenitáson itt az egyedi kibocsátási szintekben mutatkozó hasonlóságot értjük.

⁵Erre mindössze azért van szükség, mert így a kibocsátásra kapott értékek kezelhető keretek között maradnak. A ρ paraméter szélsőséges értékeire az eredményváltozók tendenciája nem változik meg, csupán azok értéke is szélsőséges, ami a vizuális megjelenítést problematikusá teszi.

jegyezni, hogy ρ közvetlen hatását kiszűrtük az elemzésből, azaz valamennyi ρ értéknél a $p = 0$ esetén kapott kibocsátási szintet egységnyinek tekintjük.


Azt látjuk, hogy a p paraméter hatása továbbra is megmarad, ugyanakkor a hatás mértéke attól függően változik, hogy ρ értéke mekkora. Ezen felül, ρ értékének változása önmagában is hatással van a kibocsátás értékére, adott p esetén: minél alacsonyabb ρ értéke, annál magasabb kibocsátást kapunk eredményül (adott p mellett), és fordítva. Az eredmények értelmezéséhez érdemes először a ρ paraméter interpretációját megadnunk.

A ρ paramétert a tudás-aggregátor definiálásakor úgy határoztuk meg, mint a partner-vállalatoktól érkező tudásbázisok közötti helyettesítés paraméterét. $1/(1 - \rho)$ ennek megfelelően a helyettesítés rugalmasságát méri ebben a kontextusban. Minél nagyobb ρ értéke (és ennek megfelelően a helyettesítés rugalmassága), annál könnyebben helyettesíthetők egymással a különböző vállalatoktól származó tudás-elemek. $\rho = 1$ esetén a helyettesítés tökéletes, vagyis a vállalatok számára közömbös, hogy melyik vállalattól érkezik a tudás. $\rho < 1$ esetén azonban a különböző vállalatoktól származó tudás-elemek addicionális értékkel bírnak (bár megjegyzendő, hogy itt nem kiegészítő viszonyról van szó, hiszen az $\rho > 1$ esetén adódna). A ρ paraméter így a gazdasági tevékenység alapjául szolgáló tudásbázis egyes területei közötti viszonyt reprezentálja. A kisebb helyettesíthetőség a diverzitás, a sokféleség irányába történő elmozdulást jelenti, ahol az egyes tudás-területek egyre kevésbé helyettesíthetők egymással.

Ennek tükrében az eredmények azt sugallják, hogy a helyettesíthetőség növekedése negatívan hat a kibocsátásra, ugyanakkor a sokféleség, a heterogenitás növekedése éppen ellenkezőleg. Fontos eredmény vezethető le a két paraméter kölcsönhatásából is. A hálózati struktúra hatása attól függően erősebb vagy gyengébb, hogy a tudás-területek közötti helyettesíthetőség kisebb vagy nagyobb. A helyettesíthetőség kisebb foka egyben azt is jelenti, hogy a hálózati struktúra hatása erőteljesebb lesz. A kölcsönhatás fordítva is megfigyelhető: a helyettesíthetőség hatása annál markánsabb, minél nagyobb p értéke, vagyis minél véletlenszerűbb a gazdaság működését megalapozó tudás-hálózat.

Azt látjuk tehát, hogy a gazdaság teljesítményét a hálózati struktúra és a tudás-bázis jellege együttesen határozza meg. A gazdasági teljesítmény pozitívan függ a tudás-bázis területeinek gyengébb helyettesíthetőségétől. Ez azt jelenti, a gazdasági teljesítmény számára kedvezőbb, ha a vállalatok egymástól különböző tudás-területeken működnek. Ugyanakkor a hálózati struktúra hatása is jelen van: a véletlenszerűségéből következő rövid elérési utak kedvezően hatnak a gazdaság teljesítményére, ez a hatás viszont annál inkább érzékelhető, minél kisebb a helyettesíthetőség az egyes vállalatok tudás-területei között.

A ρ paraméter részletes elemzése után a θ paraméter hatásának vizsgálatára lényegesen kevesebb teret is elegendő fordítanunk, mivel e paraméter értelmezése és hatása triviális. A paramétert spillover-paraméterként értelmeztük, vagyis azon paraméterként, amely a vállalatok közötti tudás-áramlás során fellépő veszteséget (vagy a másik nézőpont szerint nyereséget) méri. Így egyértelműen pozitív hatást várunk a paramétertől, amit a 4.4. ábra alapján a szimulációs eredmények igazolnak is.



4.4. ábra. A modell p és θ paramétereinek hatása az aggregált kibocsátásra a Watts-Strogatz modellben

Az ábra alapján elmondható, hogy a hálózati struktúra hatása markánsabban érzékelhető a spillover paraméter nagyobb értékeinél, ami logikus következtetésnek tűnik, hiszen a hálózati struktúra szerepe nyilvánvalóan jelentősebb akkor, ha a hálózaton keresztül több tudás és információ áramlik. Ugyanakkor az is látható, hogy a spillover paraméter hatása alacsony értékeknél markánsabb, majd később ez a hatás elhal. θ értékének 0-ról 0,1-re történő növekedése lényegesen nagyobb változást okoz a struktúra hatásában (a p paraméter szerepében), mint 0,8-ról 0,9-re történő növekedése. Mindazonáltal ha a kibocsátás értékét nem relatív módon (azaz valamennyi θ értéknél $p = 0$ -hoz viszonyítva) ábrázoljuk, úgy látható, hogy a spillover paraméter növekedésével a kibocsátás ceteris paribus növekszik. Ez a konklúzió azonban triviális, hiszen θ növekedésével változatlan kapcsolati szám esetén is növekszik a vállalatok által hozzáférhető tudás mennyisége, így a kibocsátás is.

Amint látható, a paraméterek hatásának elemzésére az ilyen numerikus szimulációk esetén csak korlátozott lehetőségek állnak rendelkezésre. Elvégezhető azonban egy olyan elemzés is, ahol egy analitikus levezetéshez hasonlóan a paraméterek output (endogén) változókra gyakorolt hatása nyomon követhető. Ehhez a statisztikában jól ismert Monte Carlo szimulációk elvét vesszük alapul, amelynek a lényege, hogy a modell paramétereit véletlenszerű kombinációban választjuk meg és feljegyezzük az eredményváltozók értékét. Ezt követően egy újabb véletlen kombinációra is megoldjuk a modellt és ismét feljegyezzük az eredményváltozók értékét. A lépést elegendő alkalommal megismételve az eredményváltozók és a paraméterek kapcsolatát statisztikai eszközökkel vizsgálhatjuk. A továbbiakban ezt a módszert alkalmazzuk a modellünkben, amely azt a lehetőséget is nyitva hagyja, hogy az eddig fixnek vett paraméterek értékét is bevonjuk az elemzésbe. Az egyes futtatások során feljegyezve a paraméterek aktuális értékét és a kapott eredményváltozókat egy olyan adatbázishoz jutunk, ami alapján egyszerű regresszió-analízist használva a paramétereknek

az egyes eredményváltozókra gyakorolt hatását megvizsgálhatjuk. Tekintve a módszer rugalmasságát, az eredmények strukturált kezelése jelen esetben nem igényli sok paraméter rögzítését. Ennek okán az eddig rögzített paraméterek közül ismét változó paraméterként kezeljük a két strukturális paramétert (α és σ), valamint a nominális pénzmennyiséget és a munkakínálatot (I és \bar{L}). Továbbra is rögzítjük azonban (a korábbi szinteken) a hálózat két paraméterét: a méretet (N) és az átlagos fokszaómot (R). A véletlen paraméterekkel összesen 10.000 futtatást végeztünk el. A 4.2. táblázat tartalmazza a kibocsátásra felírt egyszerű OLS regressziós modell standard outputjait.

	Koefficiens	Standard hiba	t-statisztika	
const	1902,74	334,062	5,6958	***
α	1047,3	109,057	9,6033	***
σ	345,709	108,801	3,1775	***
θ	1787,5	108,758	16,4356	***
ρ	-6614,53	544,153	-12,1556	***
p	489,416	108,344	4,5172	***
I	-1,22642	1,0899	-1,1253	
\bar{L}	6,41794	1,08902	5,8933	***

4.2. táblázat. OLS regresszió Monte Carlo szimulációk alapján, a Watts-Strogatz modellben, eredményváltozó: Y

A táblázatból kiolvasható, hogy a nominális jövedelem (vagy pénzmennyiség) kivételével valamennyi paraméter szignifikáns. A hálózati struktúrát kifejező p paraméter esetén pozitív hatást kapunk, ami a 4.1. ábrán bemutatott tendenciával azonos képet tükröz. Az aggregált termelési függvény két paramétere, α és \bar{L} pozitív hatással van a kibocsátásra, amely triviális eredmény, tekintve a termelési függvény specifikációját. A termékvariánsok közötti helyettesíthetőséget kifejező σ paraméter esetében szintén pozitív hatást kapunk, ami azt mutatja, hogy nagyobb fokú helyettesíthetőség magasabb aggregált kibocsátással párosul. Ez az eredmény tulajdonképpen a piacon érvényesülő monopol-hatások és a kibocsátás közötti összefüggést tükrözi.⁶ A spilloverek erősségét mutató θ paraméter hatása szintén pozitív, ami logikus következtetésnek tűnik, hiszen a magasabb spillover azt jelenti, hogy minden egyéb változatlanlansága mellett a vállalatokhoz több tudás áramlik más szereplőktől, így saját felhasználható tudásbázisuk magasabb lesz, ami az egyedi és az aggregált kibocsátási szintek növekedését eredményezi. A vállalatok tudása közötti helyettesíthetőséget mérő ρ paraméter esetében negatív együtthatót kapunk. Minél tökéletesebb a helyettesítés, annál kisebb kibocsátást kapunk. Ez az eredmény azt mutatja, hogy a magasabb kibocsátási szintek a vállalatok magasabb fokú heterogenitása esetén figyelhetőek meg. A sokféleség a gazdaság aggregált teljesítményét növeli. Végül megemlítjük, hogy a nominális jövedelem nincsen kimutatható hatással a kibocsátásra, ami a modell dichotomikus jellegéből nyilvánvalóan következik.

Így tehát azt látjuk, hogy a korábban feltárt parciális hatások p , ρ és θ esetén megmaradnak akkor is, ha a modell többi paraméterét is megváltoztatjuk. Ugyanakkor ha visszatekintünk

⁶Minél erősebb a vállalatok monopolereje, azaz a termékdifferenciálás foka, annál nagyobb a holtteher-veszteség. A helyettesíthetőség növekedése a homogén termékek és így a tökéletes verseny irányába mozdítja a gazdaságot, ami a holtteher-veszteséget csökkenti.

a modell 3.3. alfejezetben bemutatott speciális esetére, akkor azt látjuk, hogy az aggregált kibocsátásra kapott összefüggés az általános esetben módosul annyiban, hogy a kibocsátást magyarázó tényezők között megjelenik a termékvariánsok közötti helyettesíthetőség paramétere, σ . Az előző bekezdés gondolatmenetével ez a jelenség védhető, hiszen a szimmetrikus vállalatoknál éppen az a monopolerő tűnik el, ami e paraméter jelentőségét adja a modellben.

	<i>Koefficiens</i>	<i>Standard hiba</i>	<i>t-statisztika</i>	
const	-0,277566	0,0156673	-17,7162	***
α	0,545479	0,00511486	106,6459	***
σ	0,55114	0,00508786	108,3245	***
θ	-0,00420246	0,00510205	-0,8237	
ρ	0,0190102	0,025524	0,7448	
p	0,0125762	0,00507973	2,4758	**
I	0,00284157	5,11164e-05	55,5902	***
\bar{L}	-0,0029475	5,10748e-05	-57,7095	***

4.3. táblázat. OLS regresszió Monte Carlo szimulációk alapján, a Watts-Strogatz modellben, eredményváltozó: w


Érdeemes egy rövid gondolat erejéig megtekinteni a munkabérre, mint magyarázott változóra kapott hasonló regressziós eredményeket (4.3. táblázat). Itt azt látjuk, hogy a kapott eredmények visszatükrözik a homogén szereplőkre felírt modell eredményeit, specifikusan a (3.21') összefüggést. Az α és σ paraméterek hatása egyaránt pozitív, a nominális pénzmenyiség hatása szintén pozitív, a munkakínálat azonban érthető okokból, negatív előjellel szerepel a bérszint meghatározó tényezői között.

4.3. Skálafüggetlenség és általános egyensúly

Az előző alfejezetben részletesen megvizsgáltuk a Watts-Strogatz modell és az általunk felírt egyszerű általános egyensúlyi modell együttes működését. A 3.4.2. pontban azonban a Watts-Strogatz modell mellett bevezettünk egy alternatív hálózati modellt, amely a Barabási-Albert modell kiterjesztésének tekinthető. Ez a modell a kvázi-véletlenszerű hálózatok és a szélsőségesen skálafüggetlen (centrális vagy csillag) hálózatok közötti átmenetek modellezését teszi lehetővé. Az alábbiakban a 4.2. alfejezetben bevezetett módszertant alkalmazzuk azzal a különbséggel, hogy a gazdaság alapját képező tudás-hálózatokat a módosított Barabási-Albert modell segítségével állítjuk elő és ennek következtében a korábban használt p paraméter helyére a hasonló funkciót betöltő r paraméter kerül.

A szimulációk során alkalmazott paraméter-értékek is azonosak. Ennek megfelelően benchmarkként először egy olyan helyzetet elemzünk, melyben α és σ értéke a már ismert módon kerül meghatározásra, ρ és θ értékét rendre 0,5-nek és 0,8-nak vesszük. A hálózat jelen esetben is 50 elemű, az átlagos fokszám pedig 6.

A 4.5. ábrán jól nyomon követhető, hogy akárcsak a p paraméter a Watts-Strogatz modell esetén, az r paraméter is pozitív hatást gyakorol a kibocsátásra a módosított Barabási-




4.5. ábra. Az aggregált kibocsátás alakulása a módosított Barabási-Albert modell r paraméterének függvényében

Albert modell esetén. Ez tehát azt jelenti, hogy a skálafüggetlen struktúrával rendelkező hálózatok kedvezőbbek a tudás-áramlás szempontjából, mint a véletlenszerű hálózatok. Fontos itt is kiemelnünk, hogy az alapul szolgáló hálózati modellben az átlagos fokszám változatlan, annak ellenére, hogy a struktúra a domináns és marginális szereplők kettősége alapján alapul. Így tehát a módosított Barabási-Albert modell esetében is azt a konklúziót vonhatjuk le, hogy a hálózati struktúra önmagában (azaz a hálózati kapcsolatok egymáshoz viszonyított pozíciója) befolyásolja a gazdaság teljesítményét.


Érdekes még megfigyelni a szórás alakulását r változásával. Szemben a Watts-Strogatz modellel, ahol az adott r értékekre különböző futtatások során kapott kibocsátási értékek szórása folyamatosan emelkedik, itt a szórás először növekszik, aztán csökken, sőt, $r = 1$ -nél gyakorlatilag el is tűnik. Ennek az az egyszerű oka, hogy amíg a Watts-Strogatz modellnél p növekedésével a véletlenszerűség szerepe egyre növekedett, addig most ez éppen ellenkezőleg van. A véletlenszerűség r növekedésével csökken, hiszen $r = 1$ esetén egy szélsőségesen centralizált hálózat jön létre. Ugyan a modellünkben ez a szélsőséges centralizáltság nem jelent egyetlen központi szereplőt, a véletlenszerűség gyakorlatilag a hálózati modell kiinduló hálózatára koncentrálódik, ami azonban a teljes hálózatnak csupán egy kis részét teszi ki.

A vállalatok egyedi kibocsátási szintjeinek szórását tekintve (4.6. ábra) a kép kicsit összetettebb. Itt azt látjuk, hogy ez a szórás a skálafüggetlenség egy bizonyos fokáig emelkedik, majd pedig enyhén ugyan, de csökken. Ez az eredmény jól tükrözi a módosított Barabási-Albert modell logikáját. r alacsony értékeinél a hálózat (relatív) véletlenszerű, vagyis (relatív) jól jellemezhető egy reprezentatív vállalattal és így egy kibocsátási szinttel. Ugyanakkor r növekedésével a skálafüggetlenség válik dominánssá, a reprezentativitás megszűnik




4.6. ábra. A vállalatok egyedi kibocsátási szintjeinek relatív szórása a módosított Barabási-Albert modell r paraméterének függvényében

és a kevés és sok csomóponttal rendelkező vállalatok közötti különbségek lényegesen megnőnek. Ugyanakkor r egy kritikus szintjénél (jelen esetben ez 0,5 körül található) a hálózat ugyan még kétpólusúbbá válik, ez azonban már nincsen hatással a vállalatok közötti különbségek mértékére, mivel a sok kapcsolattal rendelkező vállalatok magas kibocsátását „kompenzálja” az alacsony kibocsátású vállalatok nagy száma.



4.7. ábra. A modell p és ρ paramétereinek hatása az aggregált kibocsátásra a módosított Barabási-Albert modellben

Folytatva a 4.2. alfejezet gondolatmenetét, azonos módszertan szerint elvégezzük a két tudás-paraméterre az összehasonlító elemzéseket. A tudás-területek közötti helyettesíthetőség tekintetében analóg eredményeket kapunk a Watts-Strogatz modellel (4.7. ábra): a helyettesíthetőség növekedése negatívan hat a hálózati struktúra kibocsátásban betöltött szerepére. Az ábra a korábbiaknak megfelelően relatív kibocsátási értékeket jelöl, azonban a negatív irányú összefüggés az abszolút értékek esetén is (értelemszerűen) jelen van. Itt tehát a Watts-Strogatz modell kapcsán elmondottakkal azonos eredményekre jutunk.



4.8. ábra. A modell p és θ paramétereinek hatása az aggregált kibocsátásra a módosított Barabási-Albert modellben

A θ paraméter hatása esetén némileg más eredményeket kapunk, mint a Watts-Strogatz modellben. A relatív értékeket tekintve azt látjuk, hogy θ a Barabási-Albert modell módosított változatában nem befolyásolja a hálózati struktúra hatását a kibocsátásra: a spillover paraméter bármely értéke mellett r azonos mértékben hat a kibocsátásra, kivételt csak θ alacsony (0-hoz nagyon közeli) értékei jelentenek. A relatív helyett abszolút mértékű elemzés ezzel együtt azt mutatja, hogy θ növekedése növeli a kibocsátást, ahogyan az a korábban elmondottak alapján triviális.

	Koefficiens	Standard hiba	t-statisztika	
const	109491	7733,63	14,1578	***
α	59790,7	2545,12	23,4923	***
σ	34638,5	2570,86	13,4735	***
θ	49836,5	2558,68	19,4774	***
ρ	-368846	12745,4	-28,9396	***
p	32092,1	2568,7	12,4935	***
I	109491	7733,63	14,1578	***
\bar{L}	59790,7	2545,12	23,4923	***

4.4. táblázat. OLS regresszió Monte Carlo szimulációk alapján, a módosított Barabási-Albert modellben, eredményváltozó: Y

Az előző alfejezetben bemutatott Monte Carlo szimulációkkal analóg elemzések eredményét mutatja a 4.4. táblázat. Az eredmények hasonló tendenciákat mutatnak, mint az előző pontban vizsgált Watts-Strogatz modell esetén kapott eredmények. Először is, az r paraméter esetében megkapjuk a 4.5. ábrán tapasztalt tendenciát, vagyis a hálózati struktúra hatására kapott parciális eredményünk fennmarad akkor is, ha a modell más paramétereit megváltoztatjuk. A termelési függvényt meghatározó paraméterek (α és \bar{L}) ebben az esetben is a triviális pozitív hatást mutatják, a termékvariánsok helyettesíthetősége is pozitív hatással van a kibocsátásra. A spillover paraméter hatása értelemszerűen most is pozitív, a tudás-bázisok helyettesíthetőségét reprezentáló ρ paraméter pedig, akár csak a Watts-Strogatz modell esetén, negatívan hat a kibocsátásra. A nominális kibocsátás együtthatója negatív és enyhén szignifikáns, amit nem tudunk a hálózati modell specifikus jellegével magyarázni, így azt az álláspontot fogadjuk el, hogy ez az eredmény az eljárás sztochasztikus jellegéből fakad, amit tükröz a t -statisztika relatíve alacsony abszolútértéke.

	<i>Koefficiens</i>	<i>Standard hiba</i>	<i>t-statisztika</i>	
const	-0,243485	0,0156879	-15,5206	***
α	0,543713	0,00516285	105,3125	***
σ	0,54983	0,00521506	105,4311	***
θ	0,00701882	0,00519035	1,3523	
ρ	-0,0185594	0,0258544	-0,7178	
p	-0,00622967	0,00521068	-1,1956	
I	0,00272394	5,2233e-05	52,1499	***
\bar{L}	-0,00291862	5,17399e-05	-56,4095	***

4.5. táblázat. OLS regresszió Monte Carlo szimulációk alapján, a módosított Barabási-Albert modellben, eredményváltozó: w

A munkabér esetében is hasonló eredményeket kapunk (4.5. táblázat), amelyek ismét megerősítik, hogy a modell paramétereit azonos módon befolyásolják az eredményváltozók értékét az aszimmetrikus vállalatok esetében, mint a szimmetrikus vállalatok feltételezése mellett.

4.4. A tudás diverzitásának szerepe

Az eddig bemutatott szimulációkat kivétel nélkül arra a speciális esetre végeztük el, amikor a vállalatok saját tudása azonos szintű, azaz a \mathbf{k} tudásvektor elemeit egynek vettük. Természetesen nagyfokú egyszerűsítés feltételezni, hogy a vállalatok szakértelme saját tudás-területükön azonos: könnyen elképzelhető, hogy a vállalatok magasabb és alacsonyabb tudásszinttel jellemezhetőek.

Az alkalmazott egyszerűsítés a numerikus szimulációk esetén természetesen nem szükségszerű, ami miatt mégis alkalmaztuk, az az, hogy az eredmények interpretációját nagy mértékben megkönnyíti a szimulációk ésszerű és korlátozott paraméterértékek mellett történő megtervezése. Amennyiben ugyanis a \mathbf{k} vektor eltér az egységvektortól, akkor meg kell határoznunk \mathbf{k} elemeinek egy adott eloszlását, amely újabb paraméterek specifikálását

igényli, ami egyrészt a szimulációk futtatásának időigényét növeli, másrészt pedig nehezebbé teszi az eredmények strukturált elemzését. A jelen szakaszban azonban feloldjuk ezt a korlátozást és megvizsgáljuk, hogy milyen hatással jár az aggregált kibocsátásra és a vállalatok kibocsátásának szóródására az, ha a vállalatok tudásszintje eltérő. Az itt bemutatásra kerülő szimulációk a korábban már meghatározott paraméter-beállítások mellett kerültek futtatásra, így az egyik változó paraméterünk a két hálózati modell saját változója, p vagy r , illetve ezen felül a \mathbf{k} vektor elemeinek eloszlását meghatározó paraméter.

A tudásvektor elemeiről feltesszük, hogy normális eloszlást követnek, 1-es várható értékkel és μ szórással. Így tehát a várható értéket rögzítettük, a szórás azonban változtatható, hiszen a tudásszintek közötti különbségeket ez a paraméter határozza meg. A szimulációk során μ értékét a $(0; 0,5)$ intervallumban változtattuk, vagyis a tudásvektor elemei $k_i \sim N(1, \mu)$ eloszlást követnek.

Az extrém $\mu = 0$ esetben értelemszerűen az eddig alkalmazott modell-verziót kapjuk, mivel ekkor \mathbf{k} valamennyi eleme pontosan egységnyi. μ maximális értékének meghatározásánál azt a szempontot vettük figyelembe, hogy az eloszlásból származó k_i értékek nagy valószínűséggel pozitív tartományba eszenek. Könnyen ellenőrizhető, hogy az imént specifikált eloszlás esetén mindössze 2,28% annak az esélye, hogy negatív értéket kapunk k_i -re. Az így adódó kis számú negatív értéket elkerülendő úgy járunk el, hogy amikor a véletlen eloszlásból negatív érték adódik, k_i -t önkényesen 0,001-nek állítjuk be.


4.4.1. Diverzitás a Watts-Strogatz modellben

Elsőként a Watts-Strogatz modell esetén vizsgáljuk a tudás diverzitásának szerepét. A 4.9. ábrán mutatjuk be, hogy a két változó paraméter, p és μ miképpen hat az aggregált kibocsátásra.

Az ábra létrehozásánál ismét a kibocsátás relatív értékeit vettük figyelembe, azonban most azzal a különbséggel, hogy nem $p = 0$, hanem $\mu = 0$ volt a bázisérték. Így tehát az ábra azt reprezentálja, hogy adott p és μ értékek mellett a kibocsátás milyen mértékben tér el a μ esetben tapasztalható kibocsátástól. Az ábrán a világos tartományok a magasabb, a sötét tartományok az alacsonyabb kibocsátási értékeket reprezentálják.


Jól látható, hogy a kibocsátás, kis mértékben ugyan, de tendenciózusan csökken μ magasabb értékeire. Az is látható ugyanakkor, hogy (ugyan kevésbé markánsan) p értéke is meghatározó: p magasabb értékeire μ hatása jobban érzékelhetővé válik: magasabb kibocsátási szintet figyelhetünk meg abban az esetben, ha a tudás szóródása kisebb, míg az értékek a alacsonyabbak μ magasabb értékei mellett. Az is világos, hogy a p paraméter esetében talált pozitív összefüggés (a paraméter és a kibocsátás között), a tudás magasabb szóródása esetén negatív irányú kapcsolattá válik: minél nagyobb a vállalati tudásszintek szóródása, a hálózat véletlenszerűbbé váló struktúrája annál inkább kisebb kibocsátási szintekhez vezet.

A kibocsátás abszolút értéke mellett érdemes megvizsgálunk a vállalatok kibocsátásának szóródását is. A 4.10. ábrán látható, hogy a kibocsátás szóródásának tekintetében nem



4.9. ábra. A modell p és μ paramétereinek hatása az aggregált kibocsátásra a Watts-Strogatz modellben


figyelhető meg olyan tendencia, amit az aggregált kibocsátás esetén tapasztaltunk. Jelen esetben a (p, μ) sík szinte valamennyi pontjában nagyjából azonos szóródást tapasztalunk. Az egyedüli kivétel p rendkívül alacsony (0,1-nélkisebb), valamint μ magas értékeire adódik. Itt ugyanis az figyelhető meg, hogy a tudásszintek szóródása a vállalatok kibocsátásának szóródását nagy mértékben növeli. Mindez viszont csak azokban a hálózati struktúrákban van így, ahol a klaszterezettség nagyon magas szintű, valamint az átlagos elérési úthossz nagyon magas. Ezekben a lokálisan strukturált hálózatokban a vállalatok eltérő tudásszintje jelentős különbségeket okoz a kibocsátásukban. Ugyanakkor, ahogy p értéke növekszik, vagyis létrejönnek a lokális csoportokat összekötő „áthidaló” kapcsolatok, ez a hatás eltűnik. Azt az eredményt kapjuk tehát az elemzésünk alapján, hogy a hálózatban létrejövő áthidaló kapcsolatok a sokféleség csökkentése irányába hatnak: az egyedi különbségek e kapcsolatok segítségével eliminálódnak. Ez az eredmény összhangban van azokkal a szociológiai kutatásokkal, amelyek az áthidaló kapcsolatoknak azt a szerepét emelik ki, amelyek a társadalmi csoportok közötti nagymértékű különbségek, elszigetelődés eliminálásában játszanak szerepet (Granovetter, 1983; Coleman, 1990; Cote és Haley, 2001). Jelen esetben ehhez a következtetéshez azt tudjuk hozzátenni, hogy a tudásszintekben meglévő különbségeket ezek az áthidaló kapcsolatok akként tudják ellensúlyozni, hogy a tudáshálózatokon (és ezeken belül az áthidaló kapcsolatokon) keresztül elérhető tudás végül a gazdasági teljesítmény homogénebb eloszlását eredményezik.



4.10. ábra. A modell p és μ paramétereinek hatása a vállalatok egyedi kibocsátási szintjeinek relatív szórására a Watts-Strogatz modellben

4.4.2. Diverzitás a módosított Barabási-Albert modellben


A továbbiakban az előző fejezetpontban bemutatott eljárást ismételjük meg a módosított Barabási-Albert modell esetére. A szimulációk paraméterei továbbra sem változnak, csupán p helyett a módosított Barabási-Albert modell r paraméterével dolgozunk. μ értéke ebben az esetben is 0 és 0,5 között változik, k_i várható értéke pedig 1.



4.11. ábra. A modell r és μ paramétereinek hatása az aggregált kibocsátásra a módosított Barabási-Albert modellben

A 4.11 ábra lényegesen tisztább tendenciát mutat μ esetében, mint amit a Watts-Strogatz modellnél kaptunk, azonban a fő következtetés itt is azonos: a tudásszintekben meglévő különbségek, tehát a vállalatok közötti heterogenitás növekedése csökkenti a gazdaság aggregált kibocsátását. Az r paraméter értékének változása nincsen hatással erre a tendenciára. Itt azonban világosan látszik, hogy alacsony r értékeknél a kibocsátás szóródása nagyobb, μ valamennyi értéke mellett. Mivel r alacsony értékei mellett a hálózat a véletlen hálózathoz hasonló jellemzőkkel bír, így azt a következtetést vonhatjuk le, hogy a kibocsátás nagyobb szóródása itt is – akárcsak a Watts-Strogatz modellben p magasabb értékei mellett – a hálózati struktúra véletlenszerűségéből fakad. Amint a véletlenszerűség szerepe csökken (r értéke növekszik), úgy a kibocsátás szóródása is kisebb lesz, ami a fenti ábrán jól látható.

A 4.12. ábra mutatja a tudásszintek szóródásának hatását a vállalatok kibocsátásának szóródására. A Watts-Strogatz modellel szemben itt r értékeinek jelentős részére a kibocsátás szóródása csökken, ha a tudásszintek szóródása nő. r alacsony értékei mellett nincsen számottevő különbség az egyes szórási értékek között, ami egyértelműen tükrözi azt a tendenciát, amit a Watts-Strogatz modellben is tapasztaltunk. Ott azt láttuk, hogy p növekedésével, vagyis ahogy a hálózat véletlenszerűsége növekszik, μ hatása elhanyagolhatóvá válik. A módosított Barabási-Albert modell esetén ugyancsak azt találjuk, hogy a véletlenszerű hálózat esetén (alacsony r értékek mellett) μ hatása nem érzékelhető. Ahogy azonban r nő, azaz a hálózat a véletlenszerűtől egy speciális struktúrával rendelkező hálózat felé tart, μ szerepe érzékelhetővé válik. Ugyanakkor nincsen jelentős különbség μ hatásában r különböző értékei mellett.



4.12. ábra. A modell r és μ paramétereinek hatása a vállalatok egyedi kibocsátási szintjeinek relatív szórására a módosított Barabási-Albert modellben

A kapott eredmény rendkívül érdekes. Úgy tűnik, hogy a lokálisan sűrű szabályos hálózatok esetében tapasztalt tendencia itt megfordul: a skálafüggetlen hálózatoknál a vállalatok

közötti tudásbeli vagy technológiai különbségek növekedése nem a vállalatok kibocsátása közötti különbségek növekedéséhez, hanem éppen ellenkezőleg, e különbségek csökkenéséhez vezet. Minél nagyobbak a különbségek tehát a vállalatok között a tudásszintek tekintetében, annál kisebbek lesznek a vállalatok egyedi kibocsátási szintjei közötti különbségek. Úgy tűnik tehát, hogy a gazdasági tevékenység alapjául szolgáló skálafüggetlen tudás-hálózatok egy fontos funkciót töltenek be: az egyéni szintű heterogenitást aggregált szinten homogenitássá képesek konvertálni, legalábbis ami a vállalatok gazdasági teljesítményét illeti.

4.5. Tudás-diffúzió statikus hálózatokban

Az eddigiekben pusztán azt vizsgáltuk, hogy milyen hatása van a hálózat struktúrájának és a modell más paramétereinek a gazdaság kibocsátására. A 2. fejezetben azonban kiemeltük, hogy a hálózatok szerepe abban rejlik, hogy az új tudást, vagyis az innovációt eljuttatja a gazdaság egyik pontjáról a másikra, egyik vállalattól a másikhoz. A 3. fejezetben felépített és az eddigiekben vizsgált modell kifejezetten alkalmas arra, hogy ezt a kérdéskört a segítségével megvizsgáljuk. Ehhez azonban arra van szükség, hogy a vállalatokat alapvetően jellemző \mathbf{k} tudásvektor elemeit ne konstansnak, hanem változónak fogjuk fel.

Az innováció beépítése a modellbe több módon is lehetséges, itt a lehető legegyszerűbb módozatot fogjuk alkalmazni. Az innovációval, elsősorban a gazdasági növekedéssel foglalkozó irodalom számos olyan modellt fejlesztett ki, amelyben az innováció a vállalatok tudatos döntésének eredménye (lásd pl. Barro és Sala-i-Martin, 1995). A vállalatok endogén innovációs döntéseinek figyelembevétele azonban túlságosan bonyolítaná a modellünket, ugyanakkor az innováció terjedésének és e terjedés gazdasági tevékenységre gyakorolt hatásának vizsgálatához erre nincs is feltétlenül szükség. Elegendő, ha az innovációt valamilyen exogén folyamatként kezeljük, amely aztán a statikus hálózatokon keresztül terjed a gazdaságban. A továbbiakban ezt a vonalat követjük és megvizsgáljuk a hálózati struktúra és a modell többi paraméterének hatását az innováció terjedésére, vagy másként a technológiai sokkok lecsengésének alakulására.

A 4.5.1. fejezetpontban komparatív statikus vizsgálatot végzünk, amelyben a technológiai sokk következtében bekövetkező változásokat elemezzük, azonban nem vesszük figyelembe az idődimenziót. A 4.5.2. fejezetpontban ezzel szemben az új tudás terjedését az idődimenzió figyelembe vételével vizsgáljuk meg.


4.5.1. Technológiai sokkok közvetlen hatásai

Az alábbiakban azt vizsgáljuk meg, hogy mi történik abban az esetben, ha a gazdaság egyetlen szereplőjét (a hálózat valamely tagját) egyszeri, tartós technológiai sokk éri. Modellünkben ez azt jelenti, hogy a \mathbf{k} vektor valamely eleme megnövekszik. Minthogy modellünkben a \mathbf{k} vektor elemei csupán a hálózatban szomszédos vállalatok rendelkezésre álló tudását

befolyásolják, ezért a tudás diffúziója meglehetősen egyszerű képet mutat. Az idődimenzió kiküszöbölhető, mivel ha késleltetést is feltételezünk a tudás áramlásában, a hálózat egy pontján megjelenő új tudás a következő periódusban (ahol a periódust a tudás egy hálózati kapcsolaton történő átjutásának időszükségleteként definiáljuk) már érezheti hatását a szomszédos vállalatok hozzáférhető tudásában, ugyanakkor további hatása nincsen. Elegendő tehát pusztán az eredeti \mathbf{k}_0 és a technológiai sokk után adódó \mathbf{k}_1 tudásvektor, valamint az adott statikus hálózat által meghatározott kezdeti és végső outputokat megvizsgálni. Praktikusan ez annyit tesz, hogy e két tudásvektor és az adott hálózat által generált aggregált kibocsátási értékeket hasonlítjuk össze.

A Watts-Strogatz modellben, minthogy leírható reprezentatív szereplővel, mindegy, hogy melyik hálózati tag kapja a technológiai sokkot, a gazdaság egészére gyakorolt hatás átlagosan azonos lesz. Így egyszerűen elvégezhető egy olyan szimuláció, ahol az adott hálózati struktúra mellett meghatározzuk a kezdeti és a technológiai sokk eredményeként kapott tudásvektorok által generált egyensúlyi helyzeteket, majd a két egyensúlyi helyzetet összehasonlítjuk.

A vizsgálatot továbbra is különböző p értékek mellett végeztem el, azonban vizsgáltam a ρ paraméter hatását is. Az eddigiektől eltérően azonban most nem ρ egy specifikus tartományára végeztem el a szimulációkat, hanem három kiragadott érték mellett (ezek rendre $\rho = 0$, $\rho = 0,5$ és $\rho = 0,7$). Valamennyi (p, ρ) kombinációra 50 szimulációt futtattam le, majd ezek eredményét átlagolva adódik a végeredmény. A szimulációk során véletlenszerűen került kiválasztásra a technológiai sokk által érintett vállalat, a technológiai sokk mértéke pedig azonosan 0,1 volt valamennyi futtatás során.



4.13. ábra. A modell p és ρ paramétereinek hatása a kibocsátás változására a Watts-Strogatz modellben


A 4.13. Ábrán különböző ρ értékek mellett látható, hogy a Watts-Strogatz modell p paramétere miként hat a kibocsátás változására. Az eredmények azt mutatják, hogy a Watts-Strogatz modellben a kibocsátás változása független a hálózat struktúrájától. A hálózati struktúra változása a technológiai sokk hatását nem változtatja meg, csupán a lehetséges kimenetek szóródását növeli. Ez az eredmény logikusan értelmezhető a Watts-Strogatz modell jellemzői alapján. Egyfelől a reprezentativitás miatt értelemszerű, hogy egy adott mértékű technológiai sokk az átlagos fokszámnak megfelelő hálózati taghoz jut el, így a gazdaság aggregált kibocsátásában bekövetkező változás csupán attól függ, hogy a reprezentatív szereplőnek átlagosan mennyi kapcsolata van, illetve, hogy az átlagos fokszám körül mennyire szóródnak a tényleges kapcsolati számok. Másfelől, és ebből következően, ahogy a véletlenszerűség növekedése (p növekedésével) az egyedi fokszámok szóródását növeli, úgy a technológiai sokkok kibocsátásra gyakorolt hatásának szóródása is növekszik.

Ugyanakkor azt is látjuk, hogy a külön vizsgált ρ paraméter, vagyis a vállalatok tudás-területeinek helyettesíthetősége nem befolyásolja érdemben a technológiai sokk kibocsátásra gyakorolt hatását. Talán annyit állapíthatunk meg, hogy a paraméter értékének növekedésével a kibocsátás változásának szóródása csökken. A vállalatok egyedi kibocsátásának szóródására elvégzett vizsgálatok azt mutatják, hogy a szóródás a technológiai sokk hatására a hálózati struktúrától és a ρ paraméter értékétől függetlenül növekszik. Ez az eredmény is jól értelmezhető, hiszen a technológiai sokk a vállalatok egy részénél a rendelkezésre álló tudást és így a kibocsátást növeli, míg egy másik részénél a rendelkezésre álló tudás és a kibocsátás is változatlan. Ennek következtében a kibocsátások szóródása értelemszerűen növekszik.

Amennyiben a technológiai sokk hatását a módosított Barabási-Albert modellben kívánjuk vizsgálni, úgy a helyzet kevésbé egyértelmű, mivel itt nem értelmezhető reprezentatív szereplő. Ennek következtében nem lesz irreleváns, hogy a hálózat mely tagját érinti a technológiai sokkhatás. E probléma kezeléséhez figyelembe kell vennünk, hogy a hálózat tagjai különbözőek, és ezt a különbözőséget integrálnunk kell a technológiai sokkot szimuláló algoritmusba. A hálózat tagjai közötti különbségeket a fokszám adja meg: más pozícióval rendelkeznek a hálózatban a kevés és a sok kapcsolattal rendelkező csomópontok. Így tehát logikus, hogy a fokszám alapján kell elkülönítenünk az egyes vállalatokat a technológiai sokkok szimulációja során.

A fentieket figyelembe véve a következő eljárást alkalmaztam. A vállalatokat sorba rendezzük fokszám szerint, majd az így felállított sorrendből irányítottan választjuk ki, hogy melyik vállalatot éri a sokkhatás. A kiválasztáshoz bevezetjük a δ paramétert. Ha a paraméter értéke 0, akkor a legalacsonyabb fokszámmal rendelkező vállalatot éri a sokkhatás, míg ha a paraméter értéke egy, akkor a legmagasabb fokszámmal rendelkező vállalat kerül kiválasztásra. A szimulációkat δ hét különböző értéke mellett végezzük el. A paraméter értékeinek kiválasztását az vezette, hogy a fontos tendenciákat érzékeltessük.


A 4.14. ábrán érdekes tendenciákat láthatunk. δ különböző értékeire a vizsgált mértékű technológiai sokkhatás lényegesen különböző módon hat a kibocsátásra a hálózati struktú-



4.14. ábra. A modell r és δ paramétereinek hatása a kibocsátás változására a módosított Barabási-Albert modellben

ra különböző formái mellett. δ alacsony értékei mellett (0 és 0,5) azt látjuk, hogy a hálózat struktúráját meghatározó r paraméter növekedésével a technológiai sokk hatása aggregált szinten egyre magasabb lesz. Vagyis a hálózat skálafüggetlen jellegének erősödése a technológiai sokk hatását felerősíti, amennyiben a technológiai sokk egy periférikus vállalatot érint. Ez az eredmény összhangban áll az r paraméter hatásával kapcsolatban korábban tapasztalt tendenciákkal. A korábbi elemzések során azt láttuk, hogy a hálózat skálafüggetlen jellegének erősödése az aggregált kibocsátásra pozitívan hat. Nem meglepő tehát, hogy most azt találjuk, hogy a technológiai sokk végső hatását is erősíti a hálózati struktúra ilyen irányú változása. A helyzet jelen esetben azonban lényegesen összetettebb. Az eddigi megállapítások ugyanis csak δ relatíve alacsony értékeire igazak. Jól látható az ábrán, hogy δ magas értékeire, vagyis amikor a technológiai sokkot centrális helyzetben lévő vállalat kapja, a kép jóval árnyaltabb. A szélsőséges esetet jelentő $\delta = 1$ esetén azt látjuk, hogy a technológiai sokknak a legnagyobb hatása $r = 0$ esetén van, vagyis akkor, amikor a hálózat a lehető leginkább véletlenszerű. Ezt követően a technológiai sokk hatása csökken, majd a skálafüggetlenség erősödésével ismét emelkedik.

A $\delta = 1$ esethez képest szintén más képet ad az a helyzet, amikor a technológiai sokkot nem a legtöbb kapcsolattal rendelkező vállalat kapja, de a sokkot kapó vállalat még mindig az „élmezőnyben” helyezkedik el ($\delta = 0,9$). Ekkor r hatása végig negatív, azaz a skálafüggetlenség erősödése csökkenti a technológiai sokk hatását. Az, hogy $r = 0$ esetén a különböző δ értékekre jelentősen különböző eredményeket kapunk a technológiai sokk hatását illetően, jól tükrözi modellünknek azt a jellemzőjét, hogy a módosított Barabási-Albert modellnél $r = 0$ nem ad tökéletesen véletlenszerű hálózatot, így még ebben az esetben sem közömbös, hogy a technológiai sokk a hálózat mely tagját érinti.



4.15. ábra. A modell r és δ paramétereinek hatása a vállalatok kibocsátási szintjei szóródásának változására a módosított Barabási-Albert modellben

A 4.15. ábrán a vállalatok kibocsátásainak szóródása látható különböző δ értékek mellett. A kapott kép nagyjából hasonló, mint az aggregált kibocsátás esetén. A skálafüggetlenség növekedésével δ alacsony értékeinél egyre növekvő, míg δ magasabb értékeinél csökkenő szóródást kapunk. Az aggregált kibocsátásnál is szélsőségesebb eredményt kapunk $\delta = 1$ esetén. Egyedül ez az érték, amelynél található olyan r érték, amelyre a technológiai sokk következtében (minimális mértékben ugyan) csökkennek a vállalatok közötti különbségek a kibocsátás tekintetében. Ettől az esettől eltekintve azt látjuk, hogy a technológiai sokk nagyjából azonos mértékű hatással van a vállalatok kibocsátásának szóródására r legtöbb értéke mellett. Csupán a hálózat jelentős véletlenszerűsége mellett érzékelhető nagyobb különbség: itt nagyobb mértékben nő a szóródás, ha a hálózat inkább centrális tagjait érinti a sokkhatás, míg a periférikusabb elemek esetén ez a hatás kisebb. Kivételt ismét a $\delta = 1$ eset képez, amikor is a technológiai sokk hatása a kibocsátások szóródására megegyezik a $\delta = 0$ esetben mért értékekkel.

A kapott eredmények lényeges következtetéseket vonnak maguk után. A technológiai sokkok természetesen nem csupán véletlenszerű hatások lehetnek, hanem a fejlesztéspolitika fontos célváltozóját is képezhetik, értve ezalatt a kormányzat szándékát a technológiai sokkok létrehozására, vagy az üzleti szféra ösztönzésére, hogy a technológiai sokkot ők maguk „idézzék elő”. Modellünk arra mutat rá, hogy a gazdaságot átszövő tudás-hálózat különböző struktúrái mellett a technológiai sokk eltérő hatással járhat az aggregált szintű kibocsátásra, attól függően, hogy a hálózatban periférikus vagy központi szereplőket érinti. Ennek megfelelően nem adható általánosan érvényes recept arra, hogy a tudás-hálózatban periférikus vagy éppen centrális szerepet betöltő szereplők (vállalatok, régiók) támogatása célszerű-e.

4.5.2. Technológiai sokkok dinamikus vizsgálata

Az előbbi fejezetpontban pusztán azt vizsgáltuk, hogy egy egyszeri, tartós technológiai sokk miként befolyásolja a gazdaság kibocsátását. Ha azonban a technológiai sokkok dinamikus hatását kívánjuk vizsgálni, akkor szükséges a technológia áramlásának folyamatát is figyelembe venni.

Az előző fejezetpontban pusztán azt tudtuk vizsgálni, hogy a hálózat egy pontján megjelenő újítás milyen hatással van a közvetlen szomszédokra, mivel a (3.5) tudás-aggregátor pusztán azt teszi lehetővé, hogy egy adott vállalat növekvő tudásszintjéből a közvetlen szomszédjai részesüljenek. Mivel ennek megfelelően csupán a szomszédok hozzáférhető tudása növekszik, de saját tudása nem, így a szomszédok szomszédjai számára ennek a növekedésnek már semmilyen pozitív hozadéka nincsen.

Hogy a tudás terjedését is vizsgálhassuk, a modellt a következő kiegészítéssel látjuk el. Mindenekelőtt a diffúzió értelmezéséhez az idődimenziót is figyelembe kell vennünk. Jelölje t az időindexet. Ekkor a kiindulásul szolgáló tudásvektor \mathbf{k}_0 . E tudásvektor egy tetszőleges elemét éri a technológiai sokkhatás, így a következő periódusban a tudásvektor: $\mathbf{k}_1 = (k_{1,0}, k_{2,0}, \dots, k_{i,0} + \nu, \dots, k_{N,0})$, ahol $k_{j,t}$ a j vállalat tudásszintje a t periódusban, i jelöli annak a vállalatnak az indexét, amelyiket a technológiai sokk érinti, továbbá ν a technológiai sokk mértéke. A technológiai sokk hatása még ebben a periódusban (1. periódus) érzékelhető az i vállalat szomszédjai között. Idáig vizsgáltuk a technológiai sokk szerepét az előző fejezetpontban. Most azonban feltesszük, hogy miközben a vállalatok hozzáférnek szomszédjaik tudásához, az újítást, legalábbis részben, beépítik saját tudásbázisukba. Ez azt jelenti, hogy a következő periódusban (2. periódus) az i vállalat szomszédjainak saját tudása is növekszik valamilyen mértékben. A növekedés mértékét a spillover paraméterhez (θ -hoz) kötjük. A formális felíráshoz képezzük a tudásszintekben bekövetkező differenciát az alábbi módon:

$$\Delta \mathbf{k}_t = \mathbf{k}_t - \mathbf{k}_{t-1} \quad (4.1)$$

Logikus, hogy az első periódusban $\Delta \mathbf{k}$ elemei nullák, kivéve az i -edik helyen, ahol értéke ν -vel egyezik meg. Ezt követően a rendelkezésünkre álló, és rögzítettnek feltételezett kapcsolati mátrix segítségével könnyen megadhatjuk a hálózat összes tagjánál jelentkező tudásszint változást:

$$\mathbf{k}_{t+1} = \mathbf{k}_t + \theta \mathbf{A} \Delta \mathbf{k}_t \quad (4.2)$$

Vagy másként:

$$\Delta \mathbf{k}_t = \theta \mathbf{A} \Delta \mathbf{k}_{t-1} \quad (4.3)$$

Érdeemes kiemelni azt a tényt, hogy bár elsőrendű differenciaegyenletről van szó, így egyetlen kezdeti feltétel elegendő a rendszer dinamikájának megadásához (azaz egy $\Delta \mathbf{k}_0$ érték), ez a tudásszintek változására igaz. A tudásszintek abszolút értékeihez azonban két kezdeti periódus rögzítése szükséges. Ez logikus is, hiszen $\Delta \mathbf{k}_0$ rögzítése azt igényli, hogy adott legyen \mathbf{k}_0 és \mathbf{k}_{-1} értéke. Ez a feltétel azonban különösebb problémát nem okoz, hiszen ha \mathbf{k}_{-1} értékét tekintjük a technológiai sokkot megelőző állapotot leíró tudásvektornak, akkor értelemszerűen \mathbf{k}_0 lesz az exogén módon adott technológiai sokkot már tartalmazó tudásvektor, így tehát $\Delta \mathbf{k}_0$ értékét is rögzítettük, a differenciaegyenlet-rendszer tehát jól determinált.

Amennyiben azonban a fenti formát használjuk, úgy a technológiai sokk hatása végtelen nagyra válik. Ennek az az oka, hogy – folytatva a korábbi gondolatmenetet – a 3. periódusban az i vállalat szomszédjai is szétterítik környezetükben az általuk integrált új tudást. Így az eredeti sokkot kapó i vállalat saját tudása a 4. periódusban tovább nőne, még hozzá többszörösen, hiszen valamennyi szomszédjától „visszakapja” a már egyszer átadott tudást. Ez a gondolatmenet könnyen belátható, ha figyelembe vesszük, hogy a (4.3) összefüggés egy rendkívül egyszerű lineáris differencia egyenletrendszerrel jelent $\Delta \mathbf{k}$ -ban, melynek együttható-mátrixa $\theta \mathbf{A}$. Az egyenlet fixpontja ugyan a zérus vektor, de a fix pont stabilitása tetszőleges kapcsolati mátrix esetén nem biztosított.

Mindezek fényében a (4.3) összefüggés ebben a formájában nem alkalmas a technológiai diffúzió vizsgálatára. Sőt, amennyiben megengedjük a tudásnak a csomópontok közötti oda-vissza áramlását, miként az a (4.3) összefüggés alapján is történik (vagyis ha az i csomópont felől valamely periódusban tudás áramlik a j csomópont felé), akkor a (4.3) és az ahhoz hasonló összefüggések nem akadályozzák meg, hogy később tudás áramoljon a j csomópont felől az i csomópont felé. Így a technológiai sokk hatása kumulálódik a hálózatban és az egyensúly csak igen speciális esetekben (speciális hálózati struktúra és/vagy θ alacsony értékei mellett) lesz stabil.

Éppen ezért a további elemzésekben egy olyan módszert használunk, ahol a tudás áramlása csak egyirányú lehet olyan értelemben, hogy ugyanaz a technológiai sokk valamennyi vállalatot csupán egyszer érinthet. Vagyis, ha egy csomópontot valamely időszakban „eléri” a technológiai sokk hatása, akkor a további időszakokban érkező impulzusok már nem hatnak rá. Ezt a következőképpen építjük be a modellbe. Módosítsuk a (4.3) összefüggést az alábbiak szerint:

$$\Delta \mathbf{k}_t = (\theta \mathbf{A} \Delta \mathbf{k}_{t-1}) \circ \mathbf{d}_t \quad (4.4)$$

ahol \mathbf{d}_t egy egyeseket vagy nullákat tartalmazó vektor, mely azt rögzíti, hogy mely csomópontokat érintett korábban a technológiai sokkhatás. A Hadamard-szorzatot közönséges mátrixszorzássá alakítva:

$$\Delta \mathbf{k}_t = \mathbf{D}_t (\theta \mathbf{A} \Delta \mathbf{k}_{t-1}) \quad (4.5)$$


ahol \mathbf{D}_t egy olyan diagonális mátrix, ahol a főátló elemeit rendre \mathbf{d}_t elemei adják.

A fentiek alapján értelemszerűen adódik, hogy $d_t^i = 1$, ha az i csomópontot a t periódust megelőzően még nem érintette a sokkhatás, míg ellenkező esetben $d_t^i = 0$. \mathbf{d}_t alakulását az alábbi összefüggés adja meg:

$$d_t^i = \left\{ \begin{array}{l} d_{t-1}^i, \text{ ha } \Delta k_{t-1}^i \leq 0 \\ 0, \text{ ha } \Delta k_{t-1}^i > 0 \end{array} \right\} \quad (4.6)$$

Mindezek alapján azt adhatjuk meg, hogy \mathbf{d}_0 elemei a sokk által érintett csomópont kivételével egyesek, illetve, kihasználva a korábban elmondottakat a tudásszint változása és abszolút szintje kapcsán, megállapíthatjuk, hogy \mathbf{d}_{-1} elemei kizárólag egyesek.

Ennek a megközelítésnek egy praktikus oldala is van a numerikus szimulációk szempontjából. Ekkor ugyanis a technológiai sokk hatása a hálózat tagjai közötti elérési utak közül a leghosszabbnak megfelelő idő alatt terjed szét a hálózatban, ami legfeljebb $N - 1$ lehet, így az állandósult állapot véges számú iteráció után bekövetkezik. Egyszerű szimulációk segítségével ellenőrizhető, hogy a Watts-Strogatz modellben (adott paraméterek mellett) a leghosszabb elérési út 9.⁷ Hasonlóképpen a módosított Barabási-Albert modellben (az adott paraméterek mellett) a leghosszabb elérési út 3, ami r alacsony értékeire adódik.



4.16. ábra. Technológiai sokk dinamikus hatása a Watts-Strogatz modellben a hálózati struktúra függvényében


Vizsgáljuk először a Watts-Strogatz modellben a technológiai sokk hatását. Mivel maga a technológiai sokk ugyanazokkal a jellemzőkkel rendelkezik, mint a 4.5.1. fejezetben, csupán annak kiterjesztett változata, ezért a szimulációkat is azonos tartományban végeztük el. A paraméter-értékeket a szokásos szinteken rögzítettük ($\theta = 0,8$, $\rho = 0,5$), csupán p

⁷A Watts-Strogatz modellben a leghosszabb elérési út értelemszerűen a szabályos hálózatok, azaz $p = 0$ esetén adódik.

értékét változtattuk. Valamennyi p értékre 100 szimulációt futtatunk le és az így kapott eredményeket átlagoltuk.

A 4.16. ábrán jól nyomon követhető a technológiai sokk elterjedése a hálózatban. Az összehasonlíthatóság érdekében valamennyi bemutatott p értékre a kezdeti periódus kibocsátását egységnyiinek vesszük, majd ehhez viszonyítjuk a további periódusok kibocsátását. Az ábra alapján több tendencia is megfigyelhető. Először is, a technológiai diffúzióknak a szakirodalomban szokásosnak tekinthető S-alakú mintája jól megfigyelhető modellünkben is. Egyedüli kivételként talán a szélsőséges $p = 0$ eset tekinthető, ahol a kibocsátás növekedése megtörik a 12. periódusban. Ez a jelenség azonban nem az elégtelen számú szimulált periódus következménye, hanem a hálózati struktúra speciális jellegéből fakad. Minden további p értékre azonban a technológiai diffúzió szokásos S-görbéjét kapjuk. Másodszor, jól megfigyelhető, hogy a hálózati struktúra miként befolyásolja a terjedés sebességét, illetve a végső hatás mértékét. Minél véletlenszerűbb a hálózat, azaz minél nagyobb p értéke, annál gyorsabb a terjedés, azaz a kibocsátás annál hamarabb éri el a maximumát, ugyanakkor a sokk hatása az aggregált kibocsátás végső értéke annál kisebb. Ugyanakkor a szabályosabb hálózatokban (alacsony p értékek) a diffúzió lassabb, a végső hatás azonban nagyobb.


A technológiai sokkok dinamikus hatását hasonló módszerekkel vizsgálhatjuk a módosított Barabási-Albert modellben is. Az egyedüli különbség, hogy – mint azt az előző fejezetpontban bevezettük – a technológiai sokk „helyét” meghatározó δ paraméter figyelembevételére is szükség van.



4.17. ábra. Technológiai sokk dinamikus hatása a módosított Barabási-Albert modellben a hálózati struktúra függvényében, $\delta = 0$ esetén

A 4.17. ábrán követhető nyomon a technológiai sokk hatása különböző hálózati struktúrák mellett a Barabási-Albert modellben, ha a technológiai sokk egy marginális vállalatot érint. A kapott eredmények kissé különböznek a Watts-Strogatz modell esetén tapasztalt tenden-


ciáktól. A diffúzió gyorsabb, ha r értéke magasabb, azonban a magasabb r érték egyben magasabb végső kibocsátási szintet is jelent. Kissé változik azonban a kép r alacsonyabb értékeire, ekkor ugyanis a Watts-Strogatz modellből ismert tendenciák köszönnek vissza: a nagyobb véletlenszerűség magasabb végső kibocsátáshoz vezet. Ugyanakkor a diffúzió sebességéről nem tudunk biztosat mondani, tekintve a rövid időablakot: valamennyi r érték esetén a kibocsátás maximumát vagy a 4. vagy pedig az 5. periódusban éri el a modell. Ez a jellemző a skálafüggetlen hálózatok tipikus tulajdonságából, a rövid elérési utakból következik: a szélsőséges eset, a csillag-hálózat esetén a leghosszabb elérési út mindössze 2. Modellünkben ugyan ilyen szélsőséges esettel nem dolgozunk, azonban a rövid elérési utak lényeges velejárói a módosított Barabási-Albert modellnek. Fontos továbbá azt is megjegyeznünk, hogy a kibocsátás alakulása a módosított Barabási-Albert modellben is követi a benchmark-ként kezelhető S-görbe alakját.



4.18. ábra. Technológiai sokk dinamikus hatása a módosított Barabási-Albert modellben a hálózati struktúra függvényében, $\delta = 0,5$ esetén

A 4.18. ábra azt mutatja, hogy a kibocsátás alakulásának tendenciája nem változik lényegesen akkor, ha a technológiai sokk kevésbé periférikus vállalatot érint. Ami megfigyelhető, az a végső kibocsátási szintek közeledése r alacsonyabb értékeire. $r = 0$ esetén a végső kibocsátás alacsonyabb lesz (1,321 helyett 1,299), míg $r = 0,1$ -nél magasabb (1,256 helyett 1,272).

Amennyiben a technológiai sokk a lehető legcentrálisabb helyzetben lévő vállalatot érinti (4.19. ábra), úgy a kibocsátás alakulásának tendenciája megváltozik. r magasabb értékeire a kibocsátás végső szintje kisebb, mint r alacsonyabb értékei esetén. Elmondható ugyanakkor az is, hogy a kibocsátás végső értéke valamennyi r értéknél kisebb (a kezdeti periódus értékéhez viszonyítva), mint $\delta = 0,5$ vagy $\delta = 0$ esetén. Ezek az eredmények egybevág-



4.19. ábra. Technológiai sokk dinamikus hatása a módosított Barabási-Albert modellben a hálózati struktúra függvényében, $\delta = 1$ esetén

nak a 4.5.1. fejezetpont eredményeivel, ahol azt láttuk, hogy az azonnali, statikus hatás a kibocsátásra jelentősen különbözik δ különböző értékei mellett.

Fontos azonban kiemelnünk a különbséget is, ami a 4.5.1. fejezetpont eredményeivel szemben mutatkozik. Ott azt láttuk, hogy $\delta = 1$ esetén a technológiai sokk azonnali, közvetlen hatása $r = 0$ esetén a legnagyobb, majd r alacsony értékeire meredeken csökken, végül körülbelül $r = 0,2$ -től r magasabb értékeire fokozatosan emelkedik. Ha a 4.19. ábrán látható dinamikus hatást vizsgáljuk, akkor ettől némileg eltérő tendenciákat tapasztalunk. A végső kibocsátásra gyakorolt hatás itt is $r = 0$ esetén a legmagasabb, ez tehát nem változik. Ugyanakkor r magasabb értékeire kisebb hatást kapunk a dinamikus esetben, mint a statikus esetnél, sőt. $r = 0$ fölött a hálózati struktúra változása semmilyen hatást nem gyakorol már a végső kibocsátás alakulására. Ezzel szemben a statikus hatásoknál észrevehető különbség tapasztalható.

Összességében tehát azt állapíthatjuk meg, hogy a technológiai sokk hatása lényegesen különbözik a statikus és dinamikus esetekben: a hálózati struktúrától (p és r paraméterek) valamint a sokk „helyétől” (δ paraméter) függően ugyanaz a technológiai sokkhatás más és más hatással jár a kibocsátásra rövid- és hosszú távon. A Watts-Strogatz modell esetében az azonnali (rövid távú) hatás tekintetében nem tapasztalhattunk különbségeket a hálózati struktúra különböző értékei mellett, ami abból a tényből fakad, hogy ebben a modellben a hálózat tagjainak átlagos fokszáma azonos, így bárkit és bármilyen struktúra mellett is érvényes a technológiai sokk, a szomszédokra gyakorolt közvetlen hatás mindvégig ugyanakkora marad. Ugyanakkor dinamikus szemléletben már más képet kapunk. Az identikus azonnali hatások különböző hálózati struktúrák esetén más-más hatással lehetnek a kibocsátás végső szintjére, ha figyelembe vesszük a tudás diffúzióját a sokkot „kapó” vállalat szomszédjain

túl is. A hálózat szabályossága a diffúziót lassítja, ugyanakkor a végső hatás a kibocsátásra magasabb lesz, míg a véletlenszerűség növekedésével a diffúzió gyorsabbá válik, ugyanakkor a kibocsátás végső szintje elmarad attól, mint ami egy szabályos hálózatban elérhető.


A módosított Barabási-Albert modellben hasonló különbségeket tapasztalunk, ugyanakkor a helyzet összetettebb, ami abból következik, hogy a reprezentativitás feladása miatt nem mindegy, hogy a hálózat mely tagjait éri a technológiai sokkhatás. A közvetlen, azonnali hatások tekintetében azt látjuk, hogy a kibocsátás nagyjából azonos mértékben változik, függetlenül attól, hogy a hálózat mely szereplőjét éri a sokkhatás, ha a hálózat struktúrája jellemzően skálafüggetlen. Ha azonban a struktúra közelebb áll a véletlenszerűhöz, akkor azt látjuk, hogy a technológiai sokk hatása jellemzően nagyobb akkor, ha a sokkhatás egy központi szereplőt érint, míg kisebb, ha egy marginális szereplőt. Ez a tendencia azonban kissé módosul, amint a lehető legközpontibb szereplőket érinti a sokkhatás (vagyis azokat, akiknek a lehető legtöbb kapcsolatuk van). Ekkor azt tapasztaljuk, hogy a technológiai sokkhatás egy köztes hálózati struktúra esetén jár a legkisebb azonnali hatással, míg a szélsőségesebb struktúrák (akár a véletlenszerűség, akár a skálafüggetlenség irányába) kedvezőbben befolyásolják a kibocsátás alakulását. Ezek a tendenciák nagyjából érvényesek a dinamikus esetre is, itt inkább a hálózati struktúra szélsőséges eseteinél találkozhatunk a statikus esettől eltérő hatásokkal. Ugyanakkor lényeges következtetés, hogy a dinamikus szemléletben vizsgált hatások esetén a kibocsátás jellemzően nagyobb mértékben növekszik (tetszőleges struktúra esetén) akkor, ha a technológiai sokk marginálisabb szereplőket érint, míg kisebb mértékben, ha a technológiai sokk a központi szereplőket érinti.

4.5.3. Stacionaritás és átmeneti sokkok – egy kiegészítés

Az eddigiekben bemutatott modell és a modell segítségével elemzett technológiai sokkhatások pusztán numerikus szimulációkon alapultak. Nyilvánvalóan fontos célja a modellnek, hogy alkalmazott makrogazdasági modellekhez csatolható legyen. Jelen alfejezet éppen azt a célt szolgálja, hogy a technológiai sokkhatásoknak a modell segítségével feltárt hatásmechanizmusait egy ilyen szélesebb kontextusban is értelmezni tudjuk. Az alkalmazott makromodellek fő jellemzője a stacionaritás, azaz, hogy a külső sokkhatások következtében megváltozott makrováltozók idővel egyensúlyi értékeikhez térnek vissza. Modellünk eddigi formájában ezt a módszertant nem követi, hiszen a technológiai sokkhatások egy új, a korábbtól eltérő egyensúlyi állapotba vezetnek a gazdaságot.

Módszertani szempontból két lehetőséggel élhetünk, hogy a stacionaritást beépítsük a modellbe. Az első lehetőség pusztán azt jelenti, hogy a „releváns” makrováltozók körét módosítjuk. Az alkalmazott makromodellek (DSGE modellek) tipikusan nem szintekben (levels), hanem növekedési rátákban és/vagy arányokban (rates, ratios) kerülnek felírásra. Így a stacionárius állapot nem a GDP egy adott szintje, ahogy modellünkben eddig kezeltük, hanem a GDP növekedési rátája (lásd pl. Ratto et al., 2009, Smets és Wouters, 2007). Ezt az esetet modellünkbe tulajdonképpen nagyon egyszerűen integrálhatjuk. Tekintsük a GDP egyensúlyi növekedési rátáját 0-nak. Ekkor a technológiai sokkhatás tulajdonképpen a GDP

növekedési rátáját mozdítja ki a stacionárius állapotból, majd a sokkhatás elhalásával ez a változó visszatér a korábbi egyensúlyi állapotba.



4.20. ábra. A kibocsátás növekedési ütemének alakulása különböző hálózati modellek és struktúrák mellett

A fenti ábrán a GDP növekedési ütemét határoztuk meg a korábban elvégzett szimulációk segítségével, hat különböző esetre. Egyrészt a Watts-Strogatz modellben $p = 0,1$ és $p = 0,9$ értékek mellett, majd pedig a módosított Barabási-Albert modellben $r = 0,1$ és $r = 0,9$ értékek mellett egyszer úgy, hogy a technológiai sokk a periférikus szereplőket érinti, majd úgy, hogy a sokk kezdetben a centrális szereplőkre van hatással. A 4.20. ábrán jól látható, hogy a különböző struktúrák és a sokkhatás helye szempontjából különböző mintákat kapunk a növekedés ütemére és a növekedés időzítésére vonatkozóan.


A másik lehetőség a stacionaritás integrálása szempontjából az átmeneti sokkok beépítésének lehetősége. Ebben az esetben arról van szó, hogy a sokkhatás csupán átmeneti, azaz valamennyi szereplőnél pusztán adott ideig érvényesül, majd ezt követően elhal. Ebben az esetben az eredeti modell is stacionárius lesz, mivel a gazdaság a kiindulásul szolgáló kibocsátási szinthez tér vissza. A sokkhatás átmeneti jellegét egy egyszerű autoregresszív folyamattal írhatjuk le, amelyben az autoregresszív paraméter (h) értéke 0 és 1 közé esik. A vállalatok saját tudásvektorára felírt mozgásegyenletet ezek alapján a következőképpen módosítjuk:

$$\mathbf{k}_t = \mathbf{k}_0 + h(\mathbf{k}_{t-1} - \mathbf{k}_0) + \Delta \mathbf{k}_{t-1} \quad (4.7)$$

ahol $\Delta \mathbf{k}_t$ a (4.4) összefüggés szerint definiált. A (4.7) összefüggés némi átalakítással az alábbi formára alakítható:

$$\mathbf{k}_t = (1 - h)\mathbf{k}_0 + h\mathbf{k}_{t-1} + \Delta\mathbf{k}_{t-1} \quad (4.8)$$

ami az autoregresszív folyamatok standard felírásával analóg, azzal a különbséggel, hogy egy adott periódusban érkező véletlen sokk csak a következő periódusban gyakorol hatást a vizsgált változó értékére. Ebben az esetben a $\Delta\mathbf{k}_t$ kifejezés felel meg az AR folyamat véletlen sokkhatásának. Amennyiben h értékét 1-nek vesszük, úgy a korábban már bemutatott eredményekhez jutunk, amikor a technológiai sokk hatását permanensnek tekintettük. Ha $h = 0$, akkor a technológiai sokkhatás minden egyes vállalatnál csupán egyetlen perióduson keresztül érezteti hatását. Ebben az esetben a 4.20. ábrán láthatóval azonos eredményeket kapunk, csupán itt most nem a kibocsátás növekedési pályája, hanem maga a kibocsátás írja le az ott látottakhoz hasonló pályákat.



4.21. ábra. A kibocsátás alakulása különböző hálózati modellek és struktúrák mellett átmeneti technológiai sokk esetén, $h = 0, 5$ esetén

A 4.21. ábrán láthatóak a kibocsátás által leírt pályagörbék (valamennyi esetben a kiindulási periódus kibocsátási értékét egységnyinek vettük). A kapott kép nagy mértékben hasonlít a 4.20. ábra tendenciáihoz, pusztán azzal a különbséggel, hogy az autoregresszív folyamat miatt a technológiai sokk hatása viszonylag sokáig érezhető a gazdaságban.

A technológiai diffúzió kapcsán elmondottak világosan felhívják a figyelmet egy nagyon fontos következtetésre: amennyiben a tudáshálózatok explicit szerepét figyelembe vesszük a technológiai sokkok propagációs mechanizmusa során, úgy ezek a sokkhatások – még ha az egyes vállalatoknál egyszerű autoregresszív folyamatok is írják le a technológia alakulását – a gazdaság egészének a szintjén az autoregresszív folyamattól lényegesen eltérő pályát ír le a kibocsátás alakulása. Ez alatt azt értjük, hogy az autoregresszív folyamat során a technológiai sokk hatása a legnagyobb akkor, amikor maga a sokk éri a gazdaságot, majd a hatás egyre kisebb. Hálózati modellünkben azt tudjuk bizonyítani, hogy a hálózati

struktúrától függetlenül a technológiai sokk hatása a kibocsátásra „púpos” pályagörbét ad eredményül, azaz a sokk hatása a sokkot követő periódusokban a legnagyobb, ami a tudás hálózatban történő szétterjedésével magyarázható.

Ez az eredmény fontos adalékot jelent a technológiai sokkok modellezése szempontjából. Modellünk ugyanis rámutat, hogy a technológiai sokkok kibocsátásra gyakorolt hatása sűrűlódásoktól mentes piaci környezet esetén is késleltetett, formája pedig nem írható le elsőrendű autoregresszív folyamattal. Ez lényeges adalék a gyakorlatban alkalmazott DSGE modellek szempontjából, ahol a technológiai folyamatot AR(1) folyamatként írják le. Természetesen a fent vázolt eredmények a kibocsátás alakulására vonatkoznak, azonban ugyanezek a megfontolások levezethetőek a TFP alakulására is, hiszen a modellben rögzített munkamennyiség és termelési rugalmasság következtében kölcsönös megfeleltethetőség adódik a TFP és a kibocsátás között. Ez azért fontos, mivel az alkalmazott makroökonómiai modellek a technológiai folyamatot a TFP tekintetében ábrázolják AR folyamatként, az itt közölt eredmények azonban arra mutatnak rá, hogy a tudáshálózatok figyelembevételével makroszinten nem írható le AR(1) folyamattal a TFP dinamikája.

5. fejezet

Regionális feltalálói hálózatok és termelékenység – empirikus elemzés

Az előző két fejezet során bemutatam és elemeztem egy egyszerű általános egyensúlyi modellt, amelybe a tudáshálózatok struktúrájának szerepét is beépítettem. Az elemzés egyik legfontosabb mondanivalója az volt, hogy a tudáshálózatok struktúrája hatással van a hálózatra épülő gazdasági rendszer teljesítményére. Ebben a fejezetben és a következőben a 3. fejezet modelljének empirikus tesztelését végzem el. A jelen fejezet a modell központi elemének számító tudás-aggregátor empirikus relevanciáját vizsgálja, a következő fejezetben pedig a hálózati struktúra és a gazdasági teljesítmény közötti kapcsolatot vizsgálom.

Mielőtt azonban az empirikus vizsgálatokba belekezdenénk, egy lényeges interpretációs kitérőt kell tenni, ami abból fakad, hogy a hálózatok csomópontjai az eddigi vállalati dimenzióból átkerülnek regionális (térbeli) dimenzióba, ami azt jelenti, hogy európai régiók közötti tudáshálózatokat fogunk vizsgálni. Ez a váltás első pillanatra jelentősnek tűnhet, azonban közelebbről megvizsgálva a kérdést, számos érv hozható fel mellette. Ebben az esetben ugyanis a modell úgy interpretálható, hogy valamennyi régió vállalatai egy integrált termékpiacon és egy integrált munkapiacon jelennek meg, azaz nem vesszük figyelembe a termékpiacok és a munkapiacok regionális különbségeit, sem a munkaerő esetleges helyhez kötöttségét,¹ sem pedig a termékek régiók között felmerülő szállítási költségeit. Ugyanakkor a régiók különböznek teljes tényezőtermelékenységük tekintetében, amely saját tudás-mennyiségüktől és hálózati kapcsolataiktól függ.

Természetesen felvethető, hogy az egyre szélesebb körben népszerű SCGE (Spatial Computable General Equilibrium) modellek egyrészt a termelési tényezők migrációját, másrészt a szállítási költségek problematikáját is kezelik. A tudáshálózatok alkalmazása ebben a kon-

¹Helyhez kötöttségen azt értjük, hogy a termelési tényezők kínálata részben lokális, szemben a modellünkkel, ahol a térbeli dimenzió alkalmazása esetén a kínálat globális kínálatként jelenik meg, és a tényezők régiók közötti mobilitásának költségeit nem vesszük figyelembe.

textusban nyilvánvalóan komplexebb kép kialakítását teszi lehetővé. Ugyanakkor célunk elsősorban a tudáshálózatok hatásának és szerepének vizsgálata, és az általunk bemutatott egyszerű modell éppen azt teszi lehetővé, hogy a tudás-hálózatokat más hatásoktól függetlenül vizsgálhassuk. Bizonyos értelemben modellünk tekinthető egy SCGE modell rendkívül speciális esetének, ahol mind a szállítási költségektől, mind a migrációs költségektől eltekintünk.²

Egy további fontos szempont is felhozható, részben a legutóbbi gondolathoz kötődően. Az SCGE modellek azzal a céllal jöttek létre, hogy az általános egyensúlyi modellekbe a gazdasági tevékenység térbeli dimenzióját is bevonják, és ezzel magyarázatot adjanak a gazdasági tevékenység topológiájának alakulására. Ennek módja a szállítási költségek és a termelési tényezők lokális kínálatának explicit figyelembe vétele, ami a térbeli kapcsolatokra helyezi a hangsúlyt. Ugyanakkor jelen esetben a hangsúly a hálózati kapcsolatokra és e kapcsolatok topológiájára helyeződik. Természetesen a térbeliség kérdése nem mellékes ebből a szempontból,³ első lépésként azonban célszerűnek tűnik önmagában a hálózati kapcsolatokkal és szerepükkel foglalkozni. Modellünk ebből a szempontból jó kiindulási alapot jelent, hiszen alkalmas módosításokkal a térbeliség, vagyis az SCGE modellek adott elemei könnyen beépíthetőek.

A továbbiakban tehát a 3. fejezet tudás-aggregátorának empirikus elemzését végezzük el. Az 5.1. alfejezetben a felhasznált adatbázis leírását adjuk meg, különös tekintettel a szabadalmi együttműködési hálózatok felépítésére. Az 5.2. alfejezet az empirikus modelleket és az elemzés eredményeit tartalmazza.

5.1. Az adatbázis leírása

A disszertációban használt tudás-aggregátor empirikus vizsgálatához tulajdonképpen két adatbázis kínálta lehetőségeket használunk ki. Az egyik az Eurostat által publikált, regionális bontású adatbázis a foglalkoztatottság és a GDP tekintetében, a másik pedig egy, a Pécsi Tudományegyetem Közgazdaságtudományi Karán összeállított adatbázis, amely európai NUTS 2 szintű régiók közötti, szabadalmi együttműködésekben alapuló, tudás-hálózatokat ír le. A továbbiakban részletesen a hálózati adatbázissal foglalkozunk, mivel elemzésünk szempontjából ez jelent módszertani újdonságot.

5.1.1. Eurostat adatok

Az elemzéshez a hálózatok mellett a régiók gazdasági tevékenységére vonatkozó adatokra is szükségünk van. Ezen adatok segítségével van lehetőségünk a regionális TFP értékek becslésére, amelyet aztán a modellünk egyik alapelemének tekinthető tudás-aggregátor

²Nem véletlen a rendkívüli jelző használata, hiszen e két tényező adja az SCGE modellek alapját.

³Lásd például Carayol és Roux (2009) 2. fejezetben hivatkozott tanulmányát.

empirikus vizsgálatához fel kell használnunk. Ezek az adatok az Eurostat honlapjáról elérhető, nyilvánosan hozzáférhető regionális adatbázisból állnak rendelkezésünkre. Ez az adatbázis a régiós GDP értékekre és foglalkoztatottságra vonatkozóan biztosít információkat, amelyek segítségével a termelési függvény és így a TFP értékek megbecsülhetőek.

5.1.2. Hálózati adatbázis

A tudáshálózatokat reprezentáló adatbázist európai régiók közötti szabadalmi együttműködések alapján építettük fel. A tudás-áramlást hagyományosan szabadalmi hivatkozások alapján kezeli a szakirodalom. A tudás spilloverek irodalma elsősorban a szabadalmi hivatkozások segítségével tárja fel a gazdaság szereplői és területi egységei közötti tudás-transzfer jellemzőit (Karki, 1997; Oppenheim, 2000; Chakrabarti és szerzőtársai, 1993; Chen és Hicks, 2004; Singh 2003). Néhány kutatás a szabadalmi hivatkozások segítségével hálózatokat vizsgál, azaz a hivatkozások alapján épít fel hálózatokat. Gress (2010) technológiai területek közötti kapcsolatokat vizsgál ezzel a módszerrel az Egyesült Államok szabadalmi tekintetében. A tanulmány az egyes szabadalmak és technológiai kategóriák eredetiségére, hatékonyságára vonatkozóan állapít meg következtetéseket. Li és szerzőtársai (2007) a nanotechnológia területén vizsgálják hálózatokat szabadalmak, a szabadalmakhoz rendelt intézmények, technológiai területek és országok között. Érdekes eredményük, hogy mind a négy hálózat esetén található egy központi klaszter, amely a csomópontok és a kapcsolatok legnagyobb részét magában foglalja, valamint a skálafüggetlenség egyértelműen kimutatható.

A szabadalmi hivatkozások alkalmazása a tudás-áramlás vizsgálatában azonban több problémát is felvet, amelyek közül az egyik legfontosabb, hogy a szabadalmi dokumentáció összeállítását sokszor nem a szabadalom tulajdonosa vagy feltalálói végzik, hanem erre szakosodott szervezetek. Ennek megfelelően a hivatkozások egy része is a dokumentációt összeállítók megfontolása alapján kerül be a szabadalmi dokumentumba, így nem tükröz valódi tudás-transzfert. Ugyanakkor annak kiszűrése, hogy a hivatkozások melyik része jelent valódi tudás-transzfert, meglehetősen bonyolult és egyáltalán nem triviális feladat.


Breschi és Lissoni (2003) arra hívják fel a figyelmet, hogy a szabadalmi hivatkozások sok esetben inkább társadalmi közelséget (social proximity) tükröznek, mint tényleges tudás-áramlást. Tanulmányukban azt találják, hogy a vizsgált olasz szabadalmi hivatkozások esetében a lokalizációs hatások teljes egésze magyarázható a társadalmi közelség segítségével.

Ejermo és Karlsson (2004) javasolják, hogy a szabadalmi hivatkozások használatával kapcsolatos problémák miatt a szabadalmak feltalálói között kialakuló kapcsolatokat érdemes vizsgálni, mivel ezek a hivatkozásokhoz képest szolidabb bázisát jelentik a tudás-transzfernek. A szerzők Svédország esetében vizsgálják a feltalálói hálózatok szerepét a térbeliségben.⁴

⁴A szabadalmi adatbázisok használatának előnyeiről és hátrányairól Griliches (1990) ad összefoglalót.

A fenti megfontolások alapján a tudás-hálózatok reprezentációja érdekében egy, a szabadalmi feltalálói együttműködések alapján, regionális szintű hálózati adatbázis felépítését kezdtük meg a Pécsi Tudományegyetem Közgazdaságtudományi Karán egy kutatási projekt keretében. Az adatbázis NUTS 2 régiók közötti tudás-transzferek vizsgálatára alkalmas. A kapott hálózat természetesen súlyozott, hiszen a régiók közötti együttműködések száma változhat. A súlyozás azonban több módszer segítségével is elvégezhető. Jelen esetben két ilyen módszert alkalmazunk, amelyek között az tesz különbséget, hogy a szabadalmi feltalálói együttműködések közül miként következtetünk a régiók közötti tudás-áramlás erősségére.⁵

- Az első módszer szerint a tudás-áramlás volumenét úgy számítjuk ki, hogy a régiók közötti kapcsolat erősségét egy egységgel növeljük, amennyiben egy szabadalom esetén a két régió feltalálói működtek együtt.
- A második módszer szerint a tudás-áramlás volumenét a régiók közötti interperszonális kapcsolatok alapján határozzuk meg. A régiók közötti kapcsolat súlyát ekkor annnyival növeljük, amennyi személyes kapcsolatra utal a feltalálók száma.




5.1. ábra. Egy példa szabadalmi feltalálói együttműködésekre

Az 5.1. ábra egy egyszerű példát mutat a szabadalmi feltalálói együttműködésekre. Három régió (R1, R2 és R3) hét feltalálója (I1, . . . , I7) két szabadalmon dolgozott együtt (a sötéttel és világossal jelölt feltalálók egy-egy szabadalom feltalálói). Feltételezzük, hogy a feltalálói együttműködés kapcsolatot, tudás-áramlást jelent valamennyi résztvevő feltalálók között. Természetesen elképzelhető, hogy a szabadalom feltalálói is speciális hálózati struktúrába rendeződnek, erre vonatkozóan azonban a rendelkezésre álló adatok nem biztosítanak elegendő támpontot. Ugyanakkor a feltalálók között teljes (maximális sűrűségű) hálózat feltételezése nem feltétlenül jelent lényeges torzítást, annál is inkább, mivel egy szabadalomhoz tipikusan kis számú feltalálók tartozik, így a teljes kapcsolati háló feltételezése

⁵A két módszert szemléltetik az 5.1 és 5.2. ábrák.

nem állhat nagyon messze a valóságtól (a speciális struktúra feltevése jellemzően nagyobb feltalálói létszám esetén lenne releváns). A feltalálók közötti személyes kapcsolatokat jelölik a szaggatott vonalak. Az imént vázolt két módszer alapján kialakítható interregionális hálózatokat mutatja az 5.2. ábra.



5.2. ábra. Interregionális hálózatok felépítésének két módszere az 5.1. ábra példája alapján

Az ábra segítségével jól látható a két módszer közötti különbség. Míg az első módszerrel (az ábra a) része) a kapcsolat súlya két régió között 1-es, ha a két régió feltalálói egy szabadalomban működtek együtt, illetve 2-es, ha két szabadalom esetén. A második módszer esetén (az ábra b) része) a személyes kapcsolatokat összegezzük. Az R1 és R2 régiók közötti kapcsolat súlya így 3 lesz, mivel összesen 3 kapcsolat jött létre a régió feltalálói között: I1 és I2 között, I5 és I6 között, valamint I5 és I7 között. Mivel egy szabadalom egy tudás-egységnek nevezhető információ-halmazt takar, így az első módszer a tudás-áramlás relevánsabb képét adja, míg a második módszer talán inkább a tudás létrehozásának költségei irányába mutat elmozdulást, mivel azt mutatja, hogy milyen mértékű kooperációra volt szükség két régió között egy adott szabadalom létrehozása kapcsán. Az is látható, hogy az így létrejövő hálózat hurkokat is tartalmazhat, vagyis figyelembe vehetjük a régió belüli tudásáramlás volumenét is.⁶

Fontos kiegészítés a fentiekhez az az eset, amikor egy feltaláló több szabadalom létrehozásában is részt vesz. Ezt a helyzetet speciálisan úgy lehetne kezelni, ha a szabadalmak feltalálóihoz is külön, egyedi azonosítót rendelnénk. A felhasznált adatbázis azonban csak szöveges és nem standardizált formában tartalmazza a feltalálók neveit, így azok tisztítása, kiváltképpen az általunk kezelt milliós rekordszámnál, nagyon jelentős vállalkozás lenne. Ennek köszönhetően az 5.2. ábrához hasonló struktúrát kapunk abban az esetben is, ha adott esetben két feltaláló azonos (például I2 és I6 ugyanaz a személy). Mindezek alapján tehát ebben a speciális esetben a már bemutatott módszertant alkalmazzuk. Ennek torzító hatása egyetlen esetben tűnne problematikusnak, nevezetesen, amikor a feltaláló lakhe-

⁶A két módszer közötti különbség nem csupán a súlyok abszolút számában jelentkezik, hanem változik a kapcsolatok relatív súlya is. A bemutatott példa ezt csak a hurkok esetén tartalmazza, azonban belátható, hogy általános esetben ez a helyzet.

lyet változtat. Esetünkben azonban ez nem ad jelentős torzítást, mivel a lakhely-változtatás értelemszerűen régiók közötti tudás-áramlást jelent, igaz nem abban az interperszonális értelemben, mint amire a hálózati adatok felépítésének módszertanát építettük.

Az itt vázolthoz hasonló módszert alkalmaz Maggioni és Uberti (2006) valamint Ejermo és Karlsson (2004) is, ahogyan arra a 2. fejezet irodalmi áttekintésében kitértünk.

A hálózati adatbázis felépítéséhez az EPO által rendelkezésünkre bocsátott nyers szabadalmi adatokat, valamint az ebben az adatbázisban való keresésre használható MIMOSA szoftvert használtuk fel. Az adatbázis létrehozásának technikai kérdéseit tárgyalják Kruzslicz és szerzőtársai (2010). A felépített hálózati adatbázis azonban nem teljes körű, ami azt jelenti, hogy sem szektorálisan, sem pedig térben nem fedi le a szabadalmak teljes körét. Az adatbázis csupán az Eurostat módszertana által definiált high-tech szektorhoz kötődő szabadalmakat tartalmazza. Ez a szektoron belül hat alszektort jelent: repülés, számítástechnika és automatizált üzleti berendezések, kommunikáció technológia, lézer, félvezetők, mikro-organizmusok és géntechnológia.⁷

A területi bontást illetően az adatbázis egyelőre három ország, Németország, Franciaország és az Egyesült Királyság adatait tartalmazza teljes körűen, a többi európai ország esetén a területi információk tisztítása zajlik. Az adatok 1978 és 2005 között állnak rendelkezésre – ez azt jelenti, hogy ezen időszakon belül valamennyi évre létrehoztuk az együttműködési hálózatok adatbázisát, vagyis az adatbázis elvileg longitudinális elemzést is lehetővé tesz. Parag és Sebestyén (2009) ezt az adatbázist használva a társadalmi hálózatelemzés módszereit alkalmazva vizsgálták az együttműködési hálózatok dinamikáját.

Az év-év alapú megközelítés azonban két problémát is felvet: egy módszertani és egy elvi jellegűt. Mivel az adatbázis alapján egy adott évre számolt kapcsolati mutatók (kapcsolati intenzitások) nem a tényleges együttműködést, hanem az együttműködés manifesztációját mérik, ezért egyrészt a kapott hálózatok meglehetősen instabilak lesznek, másrészt pedig nem tükrözik ténylegesen a régiók közötti kooperációt (tudás-áramlást), mivel az vélhetően a szabadalmi kérelem benyújtását megelőzően hosszabb időszakon keresztül létezett.

A fenti probléma értékelésére definiáljuk a hálózati stabilitás fogalmát, amely a stabil kapcsolatok arányát mutatja az összes kapcsolat számához képest.⁸ Az 5.1. táblázat mutatja a stabilitás átlagos értékét a vizsgált időszak alatt az egyes alszektorokban. A mutatót kiszámoltuk az eredeti évenkénti hálózati kapcsolatok esetén, illetve egy négy éves aggregálás esetén. Ez utóbbi esetben két régió közötti kapcsolat súlya nem csupán az adott év szabadalmi együttműködéseit tükrözi, hanem a megelőző három év együttműködéseit is. Ezt a módszert gördülő elven alkalmazva valamennyi évre létre tudunk hozni egy, az adott év és a megelőző három év együttműködését, mint súlyokat tartalmazó hálózatot és ez alapján

⁷A területekhez rendelt IPC kódok a következők: repülés: B64B, B64C, B64D, B64F, B64G; számítástechnika és automatizált üzleti berendezések: B41J, G06C, G06D, G06E, G06F, G06G, G06J, G06K, G06M, G06N, G06T, G11C; kommunikáció technológia: H04B, H04H, H04J, H04K, H04L, H04M, H04N, H04Q, H04R, H04S; lézer: H01S; mikro-organizmusok és géntechnológia: C12M, C12N, C12P, C12Q; félvezetők: H01L.

⁸Stabilitás alatt azt értjük, amikor a kapcsolati mátrix cellája nem változik, azaz meglévő kapcsolat nem bomlik fel, vagy egy új kapcsolat nem jön létre.

a stabilitási mutatót kiszámítani. A módszer „vesztesége”, hogy az aggregálás miatt 3 év kiesik az elemzés köréből.

	1 éves kapcsolatok	4 éves aggregálás
Repülés	4,88%	76,47%
Számítástechnika	8,55%	74,56%
Kommunikáció-technológia	9,83%	74,59%
Lézer	5,81%	77,52%
Félvezetők	9,02%	73,99%
Mikro-organizmusok és géntechnológia	7,30%	76,17%
High-tech	12,21%	75,15%

5.1. táblázat. Hálózati kapcsolatok stabilitása a szabadalmi együttműködések 1 és 4 éves aggregálása esetén

Az 5.1. táblázatból jól látható, hogy egy éves kapcsolatok esetén valamennyi szektorban meglehetősen instabil hálózatokat találunk: a hálózati kapcsolatok alig 10%-a marad stabil évről évre. A 4 éves aggregálás során azonban ez a szám már 75% körülire nő, vagyis lényegesen stabilabb hálózatokat kapunk, ahol évről évre a kapcsolatok egynegyede változik (szűnik meg meglévő kapcsolat, vagy jön létre új).

A továbbiakban a 4 éves aggregált adatok alapján létrehozott tudáshálózati adatbázist fogjuk felhasználni, az Eurostat regionális adataival kiegészítve, hogy a 3. fejezetben bemutatott modell tudás-aggregátor függvényének empirikus tartalmat adjunk. Az ott használt módszertanhoz kapcsolódva megjegyezzük, hogy a hálózati adatbázis kialakításának fenti módszere tulajdonképpen az ott alkalmazott kapcsolati mátrix elemeit adja meg empirikus bázison.

5.2. Empirikus modellek és eredmények

Az előző alfejezetben bemutatott adatok segítségével a továbbiakban elvégezzük a tudás-aggregátor empirikus tesztelését. Felidézve a tudás-aggregátort:

$$K_i = k_i + \left[\sum_{j=1}^N \alpha_{ij} (\theta k_j)^\rho \right]^{\frac{1}{\rho}} \quad (5.1)$$

Természetesen a hálózati csomópontok eltérő értelmezése miatt az (5.1) tudás-aggregátor elemeinek értelmezése is megváltozik. Jelen esetben k_j egy adott régió saját tudásmennyiségét jelöli, θ , ρ és α_{ij} interpretációja a 3. fejezetben megadott, K_i pedig az i -edik régió összes hozzáférhető tudása. Egy ilyen aggregáltabb szinten azonban K_i -nek egy olyan interpretáció is adható, amely az empirikus vizsgálat szempontjából célravezető. Minthogy az elemzési egység most a régió, a 3. fejezet (3.3) termelési függvénye jelen esetben az i -edik régió aggregált termelési függvényét írja le. Így viszont K_i a teljes tényezőterme-

lékenység (TFP) megfelelőjének tekinthető jelen modellben, figyelembe véve ugyanakkor, hogy a tőkeállomány explicite nem jelenik meg a modellben.⁹

Az (5.1) tudás-aggregátor empirikus vizsgálata során mindezeknek megfelelően az a célunk, hogy a bal oldalon található, TFP-ént értelmezhető nagyság és a jobb oldalon álló nagyságok, a régió saját tudásmennyisége (k_i) valamint a többi régiótól a tudáshálózaton keresztül „érkező” tudás (zárójeles kifejezés) között empirikus kapcsolatot találjunk. Ehhez első lépésben a TFP értékek meghatározására van szükség, majd ezt követően az (5.1) egyenlet egy redukált formájának becslését adjuk meg.

5.2.1. A regionális TFP értékek becslése

Első lépésben tehát meghatározzuk a vizsgálatunkban szereplő régiók TFP értékét. A TFP vagy Solow-reziduum Solow (1957) cikke alapján vált a gazdasági növekedést kutató tanulmányok egyik sarkalatos elemzési eszközévé. Vonzereje egyszerű alkalmazhatóságában és könnyű interpretációjában áll. Lényegében arról van szó, hogy a gazdasági növekedésnek az elemzésbe vont (nevesített) faktorok által magyarázott részen felül fennmaradó részét e tényezők általános termelékenységében bekövetkező változásnak tekintjük (innen az elnevezés: teljes tényezőtermelékenység). Esetünkben ez az interpretáció meglehetősen egyszerű. Tekintsük a 3. fejezetben alkalmazott termelési függvényt:

$$y_i = K_i L_i^\alpha \quad (5.2)$$

ahol y_i jelen kontextusban az i régió kibocsátása, L_i az i régióban felhasznált munkamennyiség, α a munka parciális termelési rugalmassága, K_i pedig a Solow-reziduum értéke az i régióban. Figyelembe kell azonban vennünk, hogy a tőkeállomány explicit modellezésének hiányában ez az érték nem feleltethető meg maradéktalanul a Solow-reziduum hagyományos értelmezésének, ugyanígy a teljes tényezőtermelékenység elnevezés sem tekinthető teljesen pontosnak. Ami miatt mégis a TFP elnevezést használjuk, az az, hogy logikailag az általunk használt K_i értékek a termelési függvény maradéktagjaként adódnak, akárcsak a „hagyományos” növekedési modellekben a TFP értékek. Azt is ki kell azonban emelnünk, hogy modellünk elsősorban nem növekedési modell, és így ebben az esetben inkább arról van szó, hogy a növekedési modellek irodalmából a termelési függvény statisztikai becslésének módszerét kölcsönözzük.

Az (5.2) összefüggés becsléséhez rendelkezésünkre állnak a vizsgált három ország (Franciaország, Németország és Egyesült Királyság) NUTS2 régióinak GDP és foglalkoztatási adatai. Ezek az Adatok az Eurostat nyilvánosan hozzáférhető regionális adatbázisából származnak (<http://epp.eurostat.ec.europa.eu>). Mivel a szabadalmi adatokon felépített hálózati adatbázis csak a high-tech szektor adatait tartalmazza, ezért a honlapról elérhető, a régiók teljes gazdaságára vonatkozó adatokat korrigálnunk kell, hogy a high-tech szektorra

⁹Természetesen a tőkeállomány a termelési függvény K_i paraméterébe beleérthető, ahogyan erre már a 2. fejezet ide vonatkozó gondolatmenetei is sugallják.

vonatkozó becsléseket kaphassunk. Ezt a korrekciót a későbbiekben bemutatjuk, most a teljes gazdaságra (összes szektor) vonatkozó adatfeldolgozást mutatjuk be és az így kapott eredményeket közöljük, benchmarkként a további elemzések számára.

Első lépésként a nominális GDP adatokat kell reál GDP adatokká átszámítani. Ezt a műveletet egyszerűen elvégezhetjük, mivel az Eurostat közli a reálértéken számolt bruttó hozzáadott érték (Gross Value Added) éves növekedési ütemét a NUTS2 régiók esetén. A bruttó hozzáadott értéket a GDP jó közelítőjének tekintve meglehetősen egyszerű módon meghatározhatjuk a reál GDP értékeket. A kezdő időszak (esetünkben 2000, mivel ettől az évtől állnak rendelkezésre a megfelelő adatok¹⁰) GDP értékét egyben a kezdő időszak reál GDP értékének is tekintjük, majd a reál bruttó hozzáadott érték növekedési rátája segítségével képezzük a további értékeket:¹¹

$$\text{GDP}_{it}^r = \text{GDP}_{i0} \times g_{it}, t \geq 1 \quad (5.3)$$

Ahol GDP_{it}^r jelöli az i régió reál GDP értékét a t időszakban, g_{it} pedig a bruttó hozzáadott érték növekedési rátája az i régióban a t időszakban. A foglalkoztatás meghatározása során egyszerűbb dolgunk van, mivel ezek az adatsorok közvetlenül elérhetőek. Mindezek alapján rendelkezésünkre áll a regionális foglalkoztatás és reál GDP adatok időszora. Az általunk vizsgált összesen 96 NUTS 2 régió és a 8 éves időhorizont (2000-től 2007-ig) egy alkalmas panel adatbázist ad, amelynek segítségével az ismert ökonometriai módszerek segítségével az (5.2) termelési függvény megbecsülhető. Adottak tehát az (5.3) összefüggés segítségével kiszámolt reál GDP (GDP_{it}^r), valamint foglalkoztatási (EMP_{it}) adatok. Ezek alapján az alábbi panel-regressziós modellt vizsgáljuk:


$$\ln(\text{GDP}_{it}^r) = \beta_0 + \beta_1 \times \ln(\text{EMP}_{it}) + \nu_i + \varepsilon_{it} \quad (5.4)$$

A fenti specifikáció egyben azt is jelenti, hogy a panel-regressziót a véletlen hatások módszerével becsüljük meg, vagyis az egység-specifikus, de idő-invariáns ν_i értékeket véletlen változóknak tekintjük. A vonatkozó ökonometriai szakirodalom alapján ez a választás (ti. véletlen hatás a fix hatással szemben) azt teszi lehetővé, hogy a vizsgált régiókat régiók egy mintájának tekintsük, és így az alapsokaságra jellemző összefüggésekre vonatkozóan vonjunk le következtetéseket (pl. Maddala, 2001). Az 5.3. ábra grafikusán mutatja a vizsgált két változó közötti összefüggést. Az ábra elkészítéséhez az adatpontok összesített halmazát használtuk fel, ami jól látható a pont-csoportok esetén, amelyek elkülönült régiókat mutatnak. Ugyanakkor a markáns pozitív kapcsolat is jól látható.

A grafikus interpretációt alátámasztandó az alábbi táblázatban közöljük a panel-regresszió eredményét. A regresszió eredményei alapján mindkét megbecsült paraméter erősen szig-

¹⁰A nominális GDP adatok ugyan 1995-től elérhetőek, de a növekedési ráták csupán 2000-től, így a reál GDP értékeket is csak ettől az évtől tudjuk meghatározni.

¹¹Itt és a továbbiakban az empirikus tartalmú egyenletek esetén a változók szorzását (az indexekből eredő zavarokat elkerülendő) a szokásos \times szimbólummal jelöljük.



5.3. ábra. A foglalkoztatottság és a GDP közötti összefüggés három európai országban, NUTS2 régióként

nifikáns, a munkafelhasználás paramétere pedig egy körüli értéket kapott, ami az 5.3. ábra alapján vizuálisan is alátámasztható eredmény.

	<i>Együttható</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	3,961	0,157	25,281	***
log_L	1,008	0,023	43,043	***
Mean depend. var	10,664	S.D. depend. var	0,695	
Sum squared resid	24,558	S.E. of regression	0,179	
Log-likelihood	232,269	Akaike criterion	-460,54	
Schwarz criterion	-451,25	Hannan-Quinn	-456,96	

5.2. táblázat. Panel regresszió eredményei a teljes gazdaság termelési függvényére vonatkozóan

Ahogy azonban azt már korábban is jeleztük, a további elemzésekhez mind a GDP, mind pedig a munkaerő adatokat a high-tech szektorra kell leszűkítenünk. Ez a munkaerő adatok esetében triviális feladat, mivel az Eurostat adatbázisa a high-tech szektor foglalkoztatottsági adatait külön közli, így ezeket az adatokat közvetlenül felhasználhattuk. A GDP átszámítása azonban addicionális korrekciókat igényel, mivel ilyen adatok közvetlenül nem érhetőek el.¹²

A high-tech szektor GDP-jét két közelítő módszer alapján határoztuk meg: mindkét módszer során egy egyszerű korrekciós tényezőt használtunk. Az első esetben a korrekciós tényező a high-tech szektorhoz kötődő és az összes szabadalom aránya volt, az adott régióban. Ezek az adatok az Eurostat regionális adatbázisában hozzáférhetőek. Minthogy a feltalálói hálózatok esetén az Eurostat besorolását alkalmaztuk a high-tech szektorra történő szűkítés

¹²Az Eurostat ugyan közöl szektorálisan bontott GDP adatokat, ezek azonban nagyjából a legszélesebb NACE besorolás szerint tartalmazznak csak információt, így nem alkalmasak a high-tech szektor ágazatainak kiszűrésére.

során, így az itt felhasználandó adatok konzisztensek a hálózati adatbázisunkkal. Az első korrekciós tényező tehát az alábbi:

$$c_{it}^1 = \frac{\text{HTPAT}_{it}}{\text{TOTPAT}_{it}} \quad (5.5)$$

ahol i és t a szokásos módon a régió és az idő indexei, TOTPAT az összes szabadalom számát jelöli, míg HTPAT a high-tech szektorhoz kötődő szabadalmak számát. Ezek alapján a high-tech szektorra becsült GDP értékeket egyszerűen az alábbi formula alapján kapjuk:

$$\text{GDP_HT}_{it}^1 = c_{it}^1 \times \text{GDP}_{it}^r \quad (5.6)$$

Ennek a felírásnak természetesen megvan az a hátránya, hogy a szabadalomszám alapján képzett regionális high-tech GDP adatok definíció szerint korrelálnak a szabadalomszámmal, ami a továbbiakban azért lehet problematikus, mert a tudás-aggregátor becslése során a szabadalomszám mint magyarázó változó is előfordul. Éppen ezért, egyfajta kontrollként egy másik módszert is alkalmazunk: ebben az esetben nem a szabadalmak, hanem a foglalkoztatás alapján becsüljük a regionális high-tech GDP-t. Az Eurostat regionális adatbázisa külön tartalmazza a high-tech szektor foglalkoztatási adatait. Ezek alapján a második korrekciós együtthatónk az alábbi módon írható fel:

$$c_{it}^2 = \frac{\text{EMP_HT}_{it}}{\text{EMP}_{it}} \quad (5.7)$$

ahol HT_EMP a high-tech szektorban foglalkoztatottak száma. Ezek alapján a high-tech GDP második módozat szerint számolt értéke:


$$\text{GDP_HT}_{it}^2 = c_{it}^2 \times \text{GDP}_{it}^r \quad (5.8)$$

Mindazonáltal érdemes megvizsgálni a két korrekciós tényező közötti összefüggést. Az 5.4. ábrán jól látható, hogy pozitív kapcsolat figyelhető meg a szabadalmi és a foglalkoztatási arányok között.

	<i>Együttható</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	-2,685	0,031	-88,028	***
log_L	0,181	0,014	12,776	***
Mean depend. var	-3,051	S.D. depend. var	0,301	
Sum squared resid	48,033	S.E. of regression	0,269	
R-squared	0,198	Adj. R-squared	0,197	
F(1, 670)	163,233	P-value(F)	0,000	
Log-likelihood	-71,001	Akaike criterion	146,001	
Schwarz criterion	154,992	Hannan-Quinn	149,485	

5.3. táblázat. OLS regresszió eredményei a két korrekciós tényező vonatkozásában

A két korrekciós tényezőre lefuttatott regresszió-analízis ugyanakkor azt tárja fel, hogy a pozitív kapcsolat létezik, a kapcsolat szorossága azonban nem túl markáns (5.3. táblázat). Ebből azt a következtetést vonhatjuk le, hogy a két különböző korrekciós tényező alapján számított regionális GDP értékek ugyan tendenciájukban hasonlóak, vagyis tipikusan magasabb high-tech GDP értékeket kapunk a c^1 faktor alapján egy olyan régióban, ahol a c^2 faktor alapján is magas high-tech GDP-t számítottunk, azonban a két számítási mód között létezik annyi különbség, hogy a két módszer elkülönült kezelése addicionális információt rejtsen magában.



5.4. ábra. A c^1 és c^2 változók közötti összefüggés grafikus szemléltetése

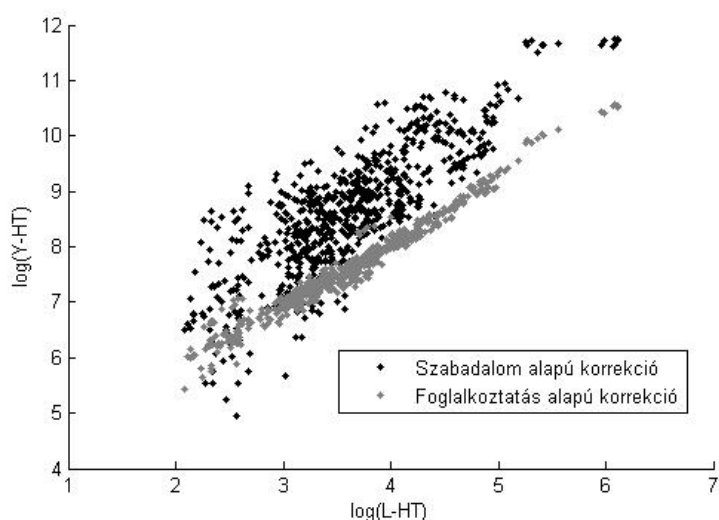
Mindezek alapján tehát rendelkezésünkre állnak azok az adatok, amelyek az (5.2) termelési függvény high-tech szektorra történő megbecsléséhez szükségesek: a szektor foglalkoztatottsága régióként és évenként ($EMP_{HT_{it}}$), valamint a high-tech szektor GDP-je a két módszer alapján számolva, régióként és évenként ($GDP_{HT_{it}}^1$ és $GDP_{HT_{it}}^2$). Ezen adatok segítségével az (5.4) regresszióhoz hasonló panel-regressziókat írhatunk fel a high-tech szektor termelési függvényére vonatkozóan:

$$\ln(GDP_{HT_{it}}^1) = \beta_0 + \beta_1 \times \ln(EMP_{HT_{it}}) + \nu_i + \varepsilon_{it} \quad (5.9a)$$

$$\ln(GDP_{HT_{it}}^2) = \beta_0 + \beta_1 \times \ln(EMP_{HT_{it}}) + \nu_i + \varepsilon_{it} \quad (5.9b)$$

Az 5.5. ábra mutatja a két regresszió pontdiagramját. A sötét pontok a szabadalmak alapján korrigált GDP-vel, a világos pontok a foglalkoztatás alapján korrigált GDP-vel számolnak, mint függő változóval.

Az ábra alapján jól látható néhány fontos összefüggés. Egyrészt a markáns pozitív irányú kapcsolat a foglalkoztatás és a GDP között a high-tech szektoron belül is kimutatható, függetlenül a szektorális GDP becslésének módjától. Ezen felül a termelés foglalkoztatás sze-



5.5. ábra. A high-tech szektor termelési függvényének képe különböző korrekciós tényezőkkel számolva

rint vett rugalmassága is nagyjából azonosnak látszik az ábra alapján. Ugyanakkor az is jól látható, hogy ha a szabadalomszám alapján becsült GDP-vel számolunk, akkor a termelési függvény nagyobb szóródást mutat. Ez az eredmény azonban logikus, hiszen a foglalkoztatás alapján számolt GDP esetén a függő változó impliciten tartalmazza a független változót, vagyis a szoros pozitív kapcsolat ebben az esetben egyáltalán nem meglepő. Az adatokban (ugyan még logaritmizálás után is, de nem túl jelentős) heteroszkedaszticitás fedezhető fel: alacsonyabb foglalkoztatottság mellett a kibocsátás szóródása nagyobb.

	<i>Együttható</i>	<i>St. hiba</i>	<i>t-stat.</i>	
Const	5,348	0,254	21,023	***
log_L	0,913	0,068	13,357	***
Mean depend. var	8,651	S.D. depend. var	1,150	
Sum squared resid	334,65	S.E. of regression	0,711	
Log-likelihood	-714,11	Akaike criterion	1432,227	
Schwarz criterion	1441,220	Hannan-Quinn	1435,712	

5.4. táblázat. Panel regresszió eredményei a high-tech szektor termelési függvényére vonatkozóan, szabadalom-alapú korrekció esetén

Az (5.9a) és (5.9b) panel-regressziók eredményei megerősítik a vizuális benyomásokat (lásd az 5.4. és 5.5. táblázatokat). Mindkét regresszió esetén szignifikáns, pozitív paramétereket kapunk. A paraméterek értéke egyhez közel esik, valamelyest alacsonyabb értékkel a szabadalmi adatokkal becsült GDP esetén.

Az eddigiekben megbecsült termelési függvény(ek) segítségével lehetőségünk nyílik arra, hogy meghatározzuk az egyes régiók TFP értékeit. Ezt egyszerűen a következő eljárással tehetjük meg. A termelési függvény becsült paramétereivel meghatározható a GDP becsült értéke az egyes régiókban és időszakokban, valamint a tapasztalati GDP adatok alapján a regresszió hibája szintén az egyes régiókban és időszakokban. Minthogy a kiszámítandó TFP érték az (5.2) termelési függvényben szereplő K_i együttható, az (5.2)

	<i>Együttható</i>	<i>St. hiba</i>	<i>t-stat.</i>	
Const	3,999	0,043	92,127	***
log_L	1,003	0,011	89,914	***
Mean depend. var	7,623	S.D. depend. var	0,837	
Sum squared resid	21,83	S.E. of regression	0,181	
Log-likelihood	192,393	Akaike criterion	-380,79	
Schwarz criterion	-371,79	Hannan-Quinn	-377,3	

5.5. táblázat. Panel regresszió eredményei a high-tech szektor termelési függvényére vonatkozóan, foglalkoztatás-alapú korrekció esetén

termelési függvény logaritmizált alakja és a regressziós eredmények segítségével könnyen megadható a TFP értéke az egyes időszakokra:

$$\ln(\text{TFP}_{it}) = \beta_0 + v_i + \varepsilon_{it} = \ln(\text{GDP}_{it}) - \beta_1 \times \ln(\text{EMP}_{it}) \quad (5.10)$$

Vagy másképpen:

$$\text{TFP}_{it} = \frac{\text{GDP}_{it}}{(\text{GDP}_{it})^{\beta_1}} \quad (5.11)$$

ahol a GDP és a foglalkoztatás adatai tetszőlegesen (de konzisztensen) választhatók meg: akár a teljes vagy a high-tech szektorra, illetve a két korrekciós módszer alapján számolva. Mindezek alapján tehát a megbecsült β_1 paramétert (paramétereket) és a GDP valamint a foglalkoztatottság idősorait felhasználva meghatározhatjuk a régiók TFP értékeit. Az 5.6. táblázatban kiemeljük a 15 legmagasabb TFP értékkel rendelkező régiót. A listát elkészítettük a high-tech szektoron és (összehasonlítás végett) a teljes gazdaságon becsült termelési függvények segítségével kiszámolt TFP értékek alapján.¹³

Az eredmények alapján jól látható, hogy a teljes gazdaságra és a high-tech szektorra vonatkozó TFP értékek jelentősen különböző sorrendet adnak: mindössze 5 régió szerepel mindkét listán: London, Ile-de-France, Oberbayern, Bremen és North Eastern Scotland. Ezek a régiók ugyanakkor a vizsgált három ország legnagyobb gazdasági központjai: London az Egyesült Királyságban, Ile-de-France (Párizs és környéke) Franciaországban, valamint Oberbayern (München és környéke) Németországban. Bréma és Észak-Skócia kissé eltér ettől a hármas tengelytől, azonban mint Hamburg és Glasgow szomszédos régiói jelenlétük már könnyen értelmezhető.¹⁴

Végül egy rövid összevetés erejéig visszatérünk a high-tech szektor regionális szintű GDP-jének becsléséhez. Mint korábban bemutattuk, két eltérő korrekciós tényezőt is használtunk, amellyel a teljes GDP értékét megszorozva a high-tech szektor GDP-jét becsültük. Az első korrekciós tényező a szabadalomszámok, a második korrekciós tényező pedig a foglalkoztatottság alapján adott közelítő értéket arra vonatkozóan, hogy a high-tech szektorhoz


¹³A high-tech szektorra itt csak a szabadalomszám alapján korrigált GDP-vel becsült eredményeket vesszük figyelembe. A foglalkoztatás alapján számolt eredményeknél hasonló sorrendet kapunk.

¹⁴A régiók teljes rangsora a függelékben található.

Teljes gazdaság			High-tech szektor	
	Régió	TFP	Régió	TFP
1.	London	98	Bretagne	868
2.	Hamburg	92	London	857
3.	Île de France	83	Provence-Alpes-Côte d'Azur	746
4.	Bremen	81	North East. Scotland	612
5.	North East. Scotland	73	Basse-Normandie	600
6.	Oberbayern	73	East Anglia	556
7.	Berksh., Bucks and Oxfordsh.	73	Gloucestershi., Wiltsh., Bristol	549
8.	Darmstadt	72	Northern Ireland	527
9.	Düsseldorf	63	Bremen	496
10.	Cheshire	63	Midi-Pyrénées	495
11.	Stuttgart	61	Ile de France	477
12.	Mittelfranken	61	Oberbayern	477
13.	Bedfordsh. Hertfordsh.	60	Hampsh. and Isle of Wight	451
14.	Gloucestersh., Wiltsh., Bristol	60	Surrey, East and West Sussex	445
15.	Karlsruhe	60	Brandenburg	404

5.6. táblázat. Becsült TFP értékek a teljes gazdaságra és a high-tech szektorra

kapcsolódó kutatási és gazdasági tevékenység milyen arányt képvisel egy adott régióban az összes kutatási és gazdasági tevékenységen belül. Láttuk, hogy a két korrekciós tényező között szignifikáns, de nem túlzottan szoros kapcsolat fedezhető fel (5.4. ábra). Ugyanakkor a további vizsgálatok szempontjából a két különböző módszer alapján becsült termelési függvényekből levezetett TFP értékek lesznek relevánsak, így érdemes egy pillantást vetni arra, hogy a TFP különböző módszerrel becsült értékei között milyen összefüggések találhatóak.



5.6. ábra. Különböző módszerrel becsült TFP értékek közötti összefüggés

Az 5.6. ábrán jól látható, hogy a két módszerrel becsült TFP értékek nagyon szoros összefüggést mutatnak. A korrekciós tényezők közötti gyengébb kapcsolatot a TFP értékek becslésénél tulajdonképpen elfedi a termelési függvény becslése során tapasztalt erős korreláció. A két változó közötti korrelációs együttható értéke 0,99, vagyis rendkívül szoros

kapcsolatról beszélhetünk. Mindezek alapján kijelenthetjük, hogy bár a két korrekciós tényező közötti összefüggés nem nagyon szoros, a két módszer alapján kapott TFP értékek gyakorlatilag megegyeznek, így nem követünk el nagy hibát, amennyiben a továbbiakban csupán az egyik módszer alapján számolt TFP értékkel dolgozunk tovább. A választás a foglalkoztatás alapján számolt TFP érték lesz, mivel így tudjuk biztosítani, hogy a magyarázó változóként megjelenő szabadalomszám mutatók és a TFP értékek közötti esetleges korrelációt ne a TFP értékben impliciten megjelenő szabadalomszám-értékek okozzák.

5.2.2. A tudás-aggregátor becslése

Az előző szakaszban meghatároztuk a vizsgálatban szereplő régiók empirikus TFP értékeit. Ezek segítségével vizsgálható a modellben központi szerepet játszó tudás-aggregátor empirikus relevanciája. A tudás-aggregátor függő változója ugyanis éppen a gazdasági egységek (esetünkben régiók) TFP értéke, független változói pedig az egységek saját és a hálózati kapcsolatokon keresztül kívülről, más egységektől hozzáférhető tudás. Ehhez azonban a TFP értékek mellett a régiók saját, és a tudáshálózatokon keresztül hozzáférhető tudásának értéke szükséges. A tudás nagyságának statisztikai mérése egy nagyon fontos problémába ütközik, nevezetesen, hogy közvetlenül nem mérhető. Erre már Krugman (1991) felhívta a figyelmet, hangsúlyozva, hogy a tudás áramlásának statisztikai mérése azért ütközik akadályokba, mert a folyamat nem hagy maga után nyomot. Jaffe és szerzőtársai (1993) ugyanakkor cáfolták Krugman fenti álláspontját, arra hivatkozva, hogy a tudás áramlása nyomon követhető többek között a szabadalmi hivatkozások segítségével.

Megállapítható tehát, hogy alkothatók olyan közelítő változók, amelyek alkalmasak a tudásállomány nagyságának és a tudás áramlásának mérésére: az empirikus elemzések ezt a lehetőséget igyekeznek is kihasználni. Többféle módszer és indikátor képzelhető el, amelyek egy ország, régió vagy kisebb gazdasági egység tudását mérni képesek. Ezek közül talán a legáltalánosabban használt indikátorok az imént már említett szabadalmi adatbázisok információin alapulnak. Ez a megközelítés alapvetően azon a megfontoláson alapul, hogy a szabadalmak egyfajta írásos nyomát jelentik a létrejövő új tudásnak, így a szabadalmak egyszerű leszámolásával egyfajta közelítő értékét kaphatjuk a gazdaság számára elérhető tudásnak.

Természetesen a szabadalmak használata számos problémát felvet. Egyfelől korántsem biztos, hogy az innovációk eredményei (és így az ezekben rejlő új tudás) szabadalmazásra kerülnek. Sőt, megfigyelhető, hogy a szabadalmazási hajlandóság bizonyos szektorális eltéréseket mutat.¹⁵ Egy másik probléma a szabadalmak egyszerű leszámolásával, hogy nem tesz különbséget az egyes szabadalmak, „tudás-elemek” súlya között. Ez a probléma szabadalmi hivatkozások segítségével természetesen orvosolható, ekkor viszont a hivatkozásokkal kapcsolatban korábban elmondottak jelentenek újabb nehézséget. További hiányosság,

¹⁵Ez a hajlandóság tipikusan magasabb a high-tech ágazatokban, vagyis azokon a területeken, amelyek az elemzés alapját képezik. Így megállapíthatjuk, hogy ez a jelenség az itt közölt adatokban nem jelent kivédhetetlen torzítást.

hogyan a szabadalmak tipikusan technológiai tudást jelenítenek meg, így a tudásbázis nem teljes spektrumát képesek mérni a szabadalmakon alapuló indikátorok.

Ezt az utóbbi hiányosságot próbálják kiküszöbölni az ún. tudományometriai módszerek (scientometrics), ahol a technológiai tudás helyett a tudományos tudást reprezentáló tudományos publikációkban rejlő információt használják fel. A szabadalmakhoz hasonlóan itt is a publikációk egyszerű leszámllálása minősül a legegyszerűbb módszernek, de a tudományos publikációk és hivatkozások tartalmazó adatbázisok számos további lehetőséget kínálnak.

A tudás írott nyomain túl egy gazdaság tudásállománya nagy részben az emberekben is található, így a tudásállomány közelítésének fontos eleme lehet az emberi tőke állománya is. Ezt a legtöbb esetben a népesség vagy a munkaerő képzettség szerint bontásával és a magas végzettségűek arányával közelítik. E három mutató együttes használata egy gazdaság tudásállományáról már minden bizonnyal jó közelítő képet adhat. Jelen esetben azonban csupán a szabadalmi adatok, mint a tudásállomány indikátora kerül alkalmazásra. Ennek az az oka, hogy az Eurostat által biztosított adatbázis csupán ebben az esetben tartalmazza az adatok számunkra releváns, regionális szintű részletezettségét, másfelől pedig a korábban bemutatott hálózati adatbázis is a szabadalmi együttműködések alapszik, így a konzisztens vizsgálat érdekében mindenképpen helyénvalónak tűnik a tudásállomány szabadalmakon keresztüli becslése.

5.2.2.1. Tudásállomány szabadalmakon keresztül

A fent elmondottaknak megfelelően tehát a vizsgálatunkban szereplő régiók tudásállományát a szabadalmak számán keresztül mérjük. Ennek oka az, hogy a számunkra releváns regionális szinten a szabadalmak számáról áll rendelkezésre információ. Az Eurostat vonatkozó adatbázisa azonban a szabadalmak regionálisan bontott számát két dimenzióban közli: egyfelől az összes szabadalom számát, másfelől pedig a high-tech szektorhoz kötődő szabadalmak számát. Ez számunkra azért is lényeges megkülönböztetés, mivel a feltalálói hálózatok adatbázisát az Eurostat klasszifikációja alapján szűrtük a high-tech szektorra, így ennek a bontásnak az alkalmazása fontos viszonyítási alapot képez az eredmények értékelése során.

Lényeges kérdés azonban a szabadalmi- vagy tudásállomány meghatározásának módja. Az Eurostat szabadalmi adatbázisa mind az összes, mind pedig a high-tech szektorhoz kötődő szabadalmak esetén az adott évben az EPO-hoz benyújtott szabadalmi kérelmek számát tartalmazza. Ezek az információk tehát a szabadalmi- és tudásállomány növekedését tükrözik, így szükséges, hogy e flow jellegű adatokból stock adatokat generáljunk. Jelölje PAT_{it} az i régióban a t időszakban (évben) benyújtott szabadalmak számát.

Mint arra már korábban utaltunk, az Eurostat adatbázisa az összes szabadalomszám és a high-tech szektorhoz kötődő szabadalmak számát is közli. Így végső soron két változónk adódik, amelyeket a továbbiak során fel tudunk használni az elemzéshez: az összes szabadalomszámot jelölő $TOTPAT_{it}$ és a high-tech szektorhoz kötődő szabadalmak számát jelölő

HTPAT_{it} mutató. A továbbiakban a PAT_{it} jelölést alkalmazzuk, ha pusztán szabadalomszámról beszélünk, vagyis irreleváns a szektorális megkülönböztetés, és a TOTPAT_{it} valamint a HTPAT_{it} jelöléseket, amennyiben valamelyik speciális csoportra utalunk.

Így tehát a PAT_{it} mutatószám az *i* régió tudásállományának növekedését mutatja a *t* évben. Ezek alapján a mutatószámok alapján a szabadalmak állományát vagy a tudásállományt két eltérő módszer alapján is levezettük. Az első módszer szerint egyszerűen az éves adatok kumulált összegét számoltuk ki, a rendelkezésre álló első adattól kezdődően. A tudásállomány nagyságát a *t* évben e módszer szerint az alábbi összefüggés adja meg:

$$K_STOCK_{it} = \sum_{\tau=0}^t PAT_{i\tau} \quad (5.12)$$

ahol a fent bevezetett konvenciónak megfelelően a bal- és a jobboldali változók helyére egyaránt helyettesíthetjük a teljes szabadalomszámra és a high-tech szektorhoz kapcsolódó szabadalomszámra vonatkozó értékeket. Mivel az adatbázisunk 1978-tól kezdődően tartalmaz adatokat, így ez a módszer természetesen torzít annyiban, amennyiben a számlálást nulláról kezdi, így a korai évek során a tudásállomány még nem mérhető teljes pontossággal. Ugyanakkor a számunkra releváns három év csupán 2000, 2001 és 2002, így elegendően hosszú időszak áll rendelkezésre a tudásállományok „felépülésére”.

A második módszer az előzővel szemben figyelembe veszi a felhalmozódó tudás amortizációját. Természetesen az amortizáció módjának és mértékének meghatározása egy külön tanulmány tárgya lehetne, éppen ezért jelen esetben csupán egy egyszerű közelítést alkalmazunk: gördülő módon egy adott év tudásállományának az adott évben és az azt megelőző négy évben benyújtott szabadalmak összegét tekintjük:

$$K_DSTOCK_{it} = \sum_{\tau=t-4}^t PAT_{i\tau} \quad (5.13)$$

Ezzel az amortizációt egy egyszerű hüvelykujj szabály segítségével visszük be az elemzésbe: valamennyi szabadalom „élettartamát” öt évnek vesszük. Ezzel a módszerrel az egyszerű kumulációból fakadó torzítás kiküszöbölhető, mivel 1983-tól kezdődően az adatbázis minden információt tartalmaz a tudásállományok kiszámítására vonatkozóan. Bár a használt módszer meglehetősen heurisztikus, az eredmények azt mutatják, hogy a tudásállomány mindkét módszerrel történő becslése alapján azonos eredményeket kapunk.

5.2.2.2. Hálózatok és külső tudás

Az előző szakaszban bemutattuk a régiók saját tudásállományának mérési módszerét. A tudás-aggregátor vizsgálatához azonban a külső, vagyis más régiókból érkező tudás becslésére is szükség van. Az (5.1) tudás-aggregátort egyszerűen átalakítva kapjuk, hogy:

$$K_i = k_i + \theta \left[\sum_{j=1}^N a_{ij} (k_j)^\rho \right]^{\frac{1}{\rho}} \quad (5.14)$$

ρ értékét egynek választva egy egyszerű lineáris összefüggést kapunk, ami hagyományos statisztikai eszközökkel már könnyen kezelhető:

$$K_i = k_i + \theta \sum_{j=1}^N a_{ij} k_j \quad (5.15)$$

Mátrix formában felírva ez az alábbi alakot ölti:

$$\mathbf{K} = \mathbf{k} + \theta \mathbf{A} \mathbf{k} \quad (5.16)$$

ahol \mathbf{K} a TFP értékek vektorát jelöli,¹⁶ \mathbf{k} a régiók egyedi tudásállománya, θ a spillover paraméter, \mathbf{A} pedig a hálózati kapcsolatok mátrixa, értelemszerűen zérus elemekkel a főátlóban. Az (5.16) összefüggésből a \mathbf{k} vektor az előző szakaszban leírtaknak megfelelően feltölthető empirikus tartalommal, ez jelenti a régiók saját, belső tudását. A külső tudás szerepét írja le az (5.16) egyenlet jobb oldalának második tagja, ami azonban további két tényezőtől áll össze: a belső tudás-vektorból és a kapcsolati mátrixból.

Az egyes régiók tudásállományainak vektorát tehát az 5.2.2.1. alpont módszertana szerint határozzuk meg.¹⁷ A \mathbf{k} tudásvektor tehát egy N elemű vektor, ahol N a vizsgált régiók száma. A külső tudás kiszámításának másik eleme a tudáshálózatot leíró \mathbf{A} kapcsolati mátrix. Ezt a mátrixot az 5.1.2. fejezetpont módszertana szolgáltatja számunkra. Ott láttuk, hogy a szabadalmi adatok alapján a hálózati kapcsolatok egy súlyozott mátrixát írhatjuk fel. Ezek alapján a kapcsolatok figyelembevétele terén két lehetőségünk adódik. Egyfelől kihasználhatjuk a hálózati kapcsolatok súlyozásának lehetőségét, vagyis figyelembe vehetjük, hogy az egyes régiók közötti kapcsolatok intenzitása (a régiók között áramló tudás mennyisége) különbözik. Másrészt pedig használhatjuk a 3. fejezetben alkalmazott módszert, ahol a kapcsolatok intenzitását figyelmen kívül hagyva bináris kapcsolati mátrixszal dolgozunk. A rendelkezésünkre álló súlyozott kapcsolati mátrixból ez a bináris mátrix könnyen előállítható: az új mátrix eleme egyes, ha az eredeti mátrix eleme nullánál nagyobb, egyébként nulla.

A bináris és súlyozott kapcsolati mátrix alkalmazása mellett a kapcsolati mátrix előállításánál során egy másik dimenzió mentén is megkülönböztethetünk két eltérő módszert. Az 5.1.2. szakaszban kitértünk arra, hogy a regionalizált szabadalmi adatok alapján a kapcsolati mátrix felépítése – egészen pontosan a kapcsolati mátrix súlyszámainak meghatározása – két módszer alapján is történhet (lásd a fejezet elején bemutatott 5.1. és 5.2. ábrákat).

¹⁶Jegyezzük meg, hogy a nagybetűs jelölés itt a szokásos konvencióval szemben nem mátrixot, hanem egy vektor jelöl.

¹⁷Ennek megfelelően \mathbf{k} négy különböző adatsort is jelölhet: a teljes vagy a high-tech szabadalmak alapján a kumulatív vagy amortizációs módszerrel számolt tudásállományt.

- Az első módszer szerint a tudás-áramlás volumenét úgy számítjuk ki, hogy a régiók közötti kapcsolat erősségét egy egységgel növeljük, amennyiben egy szabadalom esetén a két régió feltalálói működtek együtt.
- A második módszer szerint a tudás-áramlás volumenét a régiók közötti interperszonális kapcsolatok alapján határozzuk meg. A régiók közötti kapcsolat súlyát annyival növeljük, amennyi személyes kapcsolatra utal a feltalálók száma.

Míg az első módszer a szigorúan vett tudás-áramlásra, addig a második módszer inkább a kooperációs intenzitásra ad közelítő mérőszámot. Mindezek alapján azonban az (5.16) egyenletben szereplő \mathbf{Ak} szorzatnak többféle kiszámítási módja is lehetséges. Egyrészt a \mathbf{k} vektor meghatározható az egyszerű kumulált módszer, valamint a gördülő összegzéses módszer segítségével. Másfelől az mátrix képezhető a tudás-áramlás vagy a kooperációs intenzitás alapján, továbbá súlyozott vagy bináris mátrixként. Így tehát az \mathbf{Ak} szorzat kiszámításának összesen $2 \times 2 \times 2 = 8$ variációja képzelhető el. Ezen felül természetesen a \mathbf{k} vektor megadható a teljes szabadalomszám és a high-tech szektor szabadalomszámának alapján, ami újabb 8 lehetőséget ad, így a variációk száma 16-ra növekszik. Fel kell hívnunk ugyanakkor a figyelmet itt arra, hogy amíg a \mathbf{k} vektor high-tech és teljes szabadalomszám alapján is meghatározható, addig az \mathbf{A} kapcsolati mátrix csak a high-tech szektorra vonatkozóan áll rendelkezésünkre. Ennek megfelelően a teljes szabadalomszám alapján elvégzett becslések nem lehetnek konzisztensek, hiszen a kapcsolati mátrix miatt torzított eredményeket kapunk. Mindezek miatt a teljes szabadalomszámra elvégzett vizsgálatokat csupán benchmarknak tekintjük, az azok alapján levonható következtetéseket nem értékeljük önmagukban.¹⁸

Amennyiben \mathbf{s} -sel jelöljük a hálózatokon keresztül a régiókhoz áramló tudás vektorát, akkor az (5.1) tudás-aggregátor és az (5.16) egyenlet szellemében \mathbf{s} -re a következő egyszerű összefüggést írhatjuk fel:

$$\mathbf{s} = \mathbf{Ak} \quad (5.17)$$

Ezek alapján a továbbiakban egyszerűen NETWORK_{it} -ként hivatkozunk az \mathbf{s} vektor elemeinek empirikus megfelelőire, figyelembe véve, hogy adatbázisunk több évet fog át.

Fontos még egyszer kiemelni, hogy a PAT_{it} változóhoz hasonlóan a NETWORK_{it} változó is többféle értéket takarhat, attól függően, hogy milyen módszer alapján számítjuk ki. A fenti számbavétel alapján összesen 16 különböző módszert állapíthatunk meg, ezek azonban, mint majd látni fogjuk, lényeges eltéréseket nem tükröznek, továbbá a 16-ból 8 eset (amikor a teljes szabadalomszámot használjuk) csupán összehasonlítási alapként szolgál.

¹⁸Fontos ugyanakkor azt is megjegyezni, hogy az (5.16) egyenlet bal oldalán álló TFP érték a teljes gazdaságra vonatkozóan is rendelkezésünkre áll, így a teljes szabadalomszám alapján végzett becslések csupán a kapcsolati mátrixban rejlő torzítást tartalmazzák, ugyanakkor épp e kapcsolati mátrix képezi vizsgálatunk egyik fontos fókuszpontját.

5.2.2.3. Panel regressziók a tudás aggregátor becslésére

Az előző szakaszban bemutatottakat a változókat, amelyek segítségével az (5.1) tudás-aggregátor empirikus vizsgálata elvégezhető. A tudás-aggregátor bal oldalán szereplő TFP értékeket az 5.2.1. részben határoztuk meg, az előző szakaszban pedig a jobb oldalon szereplő két változó, a belső és külső tudás-állomány nagyságára határoztunk meg alkalmas empirikus mutatószámokat. Ezek alapján az (5.1) tudás-aggregátor alábbi empirikus formáját írhatjuk fel, $\rho = 1$ esetén:

$$\ln(\text{TFP}_{it}) = \beta_0 + \beta_1 \times \ln(\text{PAT_STOCK}_{it}) + \beta_2 \times \ln(\text{NETWORK}_{it}) + v_i + \varepsilon_{it} \quad (5.18)$$

Az (5.18) panel-regresszió idődimenziója mindössze három évre terjed ki: 2000-re, 2001-re és 2002-re. Ennek oka a következő: bár a jobb oldalon álló két változó, a szabadalom-állomány és a hálózati kapcsolatokon keresztül hozzáférhető tudás értéke az 1980-as évek elejétől 2005-ig áll rendelkezésre, a bal oldalon álló TFP értékek csak 2000-től kezdődően használhatók fel.¹⁹ A 2003-2005 közötti adatok azonban a szabadalmak szempontjából használhatók korlátozottan. Ezen az időszakon ugyanis az EPO által feldolgozott adatok köre csökken: az adatok alapján a szabadalmak száma, így mind a kapcsolati mátrixok súlyai, mind pedig az általunk levezetett külső tudás-értékek csökkennek. Ennek következtében a 2003 és 2005 közötti időszakra rendelkezésre álló hálózati és szabadalmi adatok által nyújtott információk torzítanak az eredményeket, így ezeket célszerű kihagyni az elemzésből. Így a viszonylag rövid, 2000 és 2002 közötti három éves időszakra kell korlátoznunk a vizsgálatot. Az (5.18) egyenletben a változók logaritmizálására azért van szükség, hogy a hibatagok normális eloszlása biztosított legyen.

Ahogy az előző szakaszban tárgyaltuk, az (5.18) regresszióban szereplő PAT_STOCK_{it} és NETWORK_{it} változókat különböző módszerek alapján, többféle kombinációban is kiszámíthatjuk. Ennek megfelelően az (5.18) regresszió többféle formában is megbecsülhető. Az 5.7. táblázatban foglaltuk össze a véletlen hatásokkal számolt panel-regressziós eredményeket. A táblázat csupán a legfontosabb eredményeket mutatja: az egyes változók koefficienseire kapott értékeket, valamint a szignifikancia-szinteket (ez utóbbit a csillagok száma a szokásos módon jelöli). A regressziók részletes eredményei a fejezethez tartozó függelék F2-F9 táblázataiban találhatóak.

Az eredmények alapján azt állapíthatjuk meg, hogy a vizsgálatban szereplő három ország NUTS2 régióinak becsült TFP értékei és belső tudásállománya (PAT_STOCK) között erősen szignifikáns pozitív kapcsolat található, függetlenül attól, hogy a tudásállományt milyen módon számítjuk ki (egyszerű vagy gördülő összegzéses módszerrel) – a koefficiensek értéke is nagyjából azonos. A külső tudás szerepét mutató változó paraméterei azonban összetettebbek. Először is, e változó együtthatója valamennyi esetben negatív, ami azt jelenti,

¹⁹ Ennek oka a reál GDP növekedési ütemére vonatkozó adatok korlátozott elérhetősége. Ugyan árindex adatok segítségével a reál GDP hosszabb időszakra is meghatározható lenne, ezek az árindex adatok nem érhetőek el regionális bontásban.

<i>Tudásállomány számítása</i>	Egyszerű összeg		Egyszerű összeg	
<i>Súlyszámítás</i>	Kooperáció		Szabadalomszám	
<i>Kapcsolati mátrix</i>	Súlyozott		Súlyozott	
Konstans	4,949	***	4,865	***
PAT_STOCK	0,463	***	0,463	***
NETWORK	-0,084	***	-0,080	***
<i>Tudásállomány számítása</i>	Egyszerű összeg		Egyszerű összeg	
<i>Súlyszámítás</i>	Kooperáció		Szabadalomszám	
<i>Kapcsolati mátrix</i>	Bináris		Bináris	
Konstans	4,615	***	4,615	***
PAT_STOCK	0,438	***	0,438	***
NETWORK	-0,063	*	-0,063	*
<i>Tudásállomány számítása</i>	Gördülő összeg		Gördülő összeg	
<i>Súlyszámítás</i>	Kooperáció		Szabadalomszám	
<i>Kapcsolati mátrix</i>	Súlyozott		Súlyozott	
Konstans	4,912	***	4,836	***
PAT_STOCK	0,464	***	0,464	***
NETWORK	-0,086	***	-0,082	***
<i>Tudásállomány számítása</i>	Gördülő összeg		Gördülő összeg	
<i>Súlyszámítás</i>	Kooperáció		Szabadalomszám	
<i>Kapcsolati mátrix</i>	Bináris		Bináris	
Konstans	4,464	***	4,464	***
PAT_STOCK	0,436	***	0,436	***
NETWORK	-0,050		-0,050	

5.7. táblázat. A tudás-aggregátor becslésének regressziós eredményei a high-tech szektorra vonatkozóan, eredményváltozó: régiós TFP

hogyan a magasabb külső tudásszinthez szisztematikusan alacsonyabb TFP érték járul. Ez a negatív összefüggés erősen szignifikánsnak mutatkozik minden esetben, amikor súlyozott kapcsolati mátrixot alkalmazunk, azonban kevésbé szignifikáns abban az esetben, amikor a kapcsolati mátrix bináris.

A NETWORK változó esetén kapott szignifikáns negatív együtthatók ellentmondásosak, hiszen hipotézisünk éppen pozitív kapcsolatot valószínűsít a külső tudásállomány és a TFP értékek között. Érdekes azonban megvizsgálunk az (5.18) regresszió benchmarkként szolgáló azon verzióját, ahol a TFP és a tudásállomány értékeit a high-tech szektor helyett a teljes gazdaságra vonatkozóan számítjuk ki. Az erre vonatkozó eredményeket tartalmazza az 5.8. táblázat, ahol az előzőhöz hasonlóan csak a legfontosabb értékek találhatóak meg. A részletes eredményeket a fejezethez tartozó függelék F10-F17 táblázatai tartalmazzák.

A teljes gazdaságra vonatkozó TFP értéken és az összes szabadalomszámon alapuló eredmények meglehetősen eltérő képet mutatnak a high-tech szektorra kapott eredményektől. Itt az látható, hogy a belső tudásállomány pozitív, de nem szignifikáns összefüggést mutat a TFP-vel, azonban a külső tudásállomány, eltérően az előző esettől, pozitív kapcsolatban áll a TFP-vel. A súlyozott és bináris kapcsolati mátrixok alapján mutatkozó különbség hasonló a korábban látottal: a súlyozott mátrix használata esetén a kapcsolat szignifikánsabb, mint a bináris mátrix esetén.

<i>Tudásállomány számítása</i>	Egyszerű összeg	Egyszerű összeg
<i>Súlyszámítás</i>	Kooperáció	Szabadalomszám
<i>Kapcsolati mátrix</i>	Súlyozott	Súlyozott
Konstans	2,926 ***	2,940 ***
PAT_STOCK	0,002	0,002
NETWORK	0,010 ***	0,010 ***
<i>Tudásállomány számítása</i>	Egyszerű összeg	Egyszerű összeg
<i>Súlyszámítás</i>	Kooperáció	Szabadalomszám
<i>Kapcsolati mátrix</i>	Bináris	Bináris
Konstans	2,935 ***	2,935 ***
PAT_STOCK	0,004	0,004
NETWORK	0,010 **	0,010 **
<i>Tudásállomány számítása</i>	Gördülő összeg	Gördülő összeg
<i>Súlyszámítás</i>	Kooperáció	Szabadalomszám
<i>Kapcsolati mátrix</i>	Súlyozott	Súlyozott
Konstans	2,888 ***	2,905 ***
PAT_STOCK	0,001	0,002
NETWORK	0,014 ***	0,013 ***
<i>Tudásállomány számítása</i>	Gördülő összeg	Gördülő összeg
<i>Súlyszámítás</i>	Kooperáció	Szabadalomszám
<i>Kapcsolati mátrix</i>	Bináris	Bináris
Konstans	2,876 ***	2,876 ***
PAT_STOCK	0,005	0,005
NETWORK	0,016 ***	0,016 ***

5.8. táblázat. A tudás-aggregátor becslésének regressziós eredményei a teljes gazdaságra vonatkozóan, eredményváltozó: régiós TFP

A várt pozitív kapcsolat helyett a TFP értékek és a külső tudás között feltárt negatív kapcsolat magyarázható úgy is, hogy az általunk használt empirikus változók nem pontosan azokat a jelenségeket tükrözik, amelyeket mérni szándékozunk. Ebben az esetben a mutatók megfelelő korrekciója az eddigiekhez képest pontosabb eredményekre vezet. Egy másik lehetőség ugyanakkor az, hogy a negatív kapcsolat lehetőségét a 3. fejezet modellje is tartalmazza, csupán nem a tudás-aggregátor definíciójában, hanem a hálózat struktúrájától függően a ténylegesen kiszámolt TFP értékek és a külső tudás-állományok között. A továbbiakban ezt a két lehetőséget vesszük sorra. Az 5.2.2.4. alpontban megvizsgáljuk, hogy az empirikus változók korrekciójával közelebb juthatunk-e a feltételezett pozitív kapcsolathoz, az 5.2.2.5. fejezetpontban pedig azt keressük, hogy a 3. fejezet modelljében megtalálható-e a TFP és a külső tudás közötti negatív kapcsolat, és ha igen, akkor milyen feltételek mellett.

5.2.2.4. Korrigált empirikus változók

A teljes gazdaságra kapott eredményekből az a sejtésünk lehet, hogy a high-tech szektor esetében kapott negatív összefüggés valamilyen mögöttes tendenciából fakad, amely mintegy elrejtje, felülírja a külső tudás és a TFP közötti tényleges kapcsolatot. Könnyen elképzelhető ilyen kapcsolati elem lehet a következő: a hálózati kapcsolatokon keresztül elérhető külső tudás és a TFP között talált negatív összefüggés csupán azt mutatja, hogy a mintánkban szereplő régiók esetén az alacsony TFP értékekhez tipikusan magasabb külső

tudás-érték társul. Azaz, azok a régiók, amelyek alacsonyabb TFP értékekkel jellemezhetőek, tipikusan nagyobb mértékben támaszkodnak külső kapcsolatokra, és ezeken a kapcsolatokon keresztül tipikusan több tudáshoz jutnak hozzá. Ez az eredmény, ebből a nézőpontból szemlélve, egyáltalán nem nevezhető meglepőnek. Amennyiben a magasabb TFP-vel jellemezhető régiók magasabb belső tudásállománnyal rendelkeznek (mint ahogyan eredményeink ezt mutatják), várható, hogy az alacsonyabb TFP-jű régiók a magasabb tudásállományú és magasabb TFP-jű régiókkal állnak kapcsolatban, így az általunk használt adatsorokban e régióknál a külső tudás értéke tipikusan magasabb lesz. Ennek alapján tehát logikusnak tűnik, hogy a TFP és a külső tudás között negatív kapcsolatot találunk.

E hipotézis tesztelésére megvizsgáljuk a TFP értékek és a külső kapcsolatok szerepe közötti kapcsolatot. A külső kapcsolatok szerepének értékelésére két különböző mutatót vezetünk be, amelyekhez az eredeti kapcsolati mátrixokat használjuk fel. Az 5.1.2. szakaszban bemutatott hálózati adatbázisból rendelkezésünkre álló adatok nem csupán az egyes régiók külső kapcsolatainak intenzitását tartalmazzák, hanem a régiókon belüli kapcsolatok számát is. Ez praktikus azt jelenti, hogy a rendelkezésünkre álló, nyers hálózati adatokat tartalmazó \mathbf{R} kapcsolati mátrix diagonális elemei nem nullák, hanem pozitív számok. Ezt az addicionális információt az eddigiek során nem használtuk ki, hanem az \mathbf{R} mátrix diagonális elemeit egyszerűen zérusnak vettük (így nyertük az 5.2.2.2. szakaszban használt \mathbf{A} mátrixot). Az eredeti \mathbf{R} mátrixban rejlő addicionális információt kihasználva egyszerűen képezhetünk két olyan mutatót is, amely a külső kapcsolatok fontosságát mutatja egy adott régió esetén. Az első ilyen mutató egyszerűen a külső kapcsolatok arányát mutatja az összes kapcsolaton belül:

$$\text{INTER_SHARE}_{it} = \frac{\sum_{j=1}^N r_{ij}^t - r_{ii}^t}{\sum_{j=1}^N r_{ij}^t} = 1 - \frac{r_{ii}^t}{\sum_{j=1}^N r_{ij}^t} \quad (5.19)$$

A második mutató a külső kapcsolatok számát a belső kapcsolatok számához viszonyítja:

$$\text{REL_LINK}_{it} = \frac{\sum_{j=1}^N r_{ij}^t - r_{ii}^t}{r_{ii}^t} \quad (5.20)$$

Az (5.19) és (5.20) mutatószámok tehát lehetőséget adnak arra, hogy a külső kapcsolatok szerepe és a regionális TFP értékek közötti kapcsolatot megvizsgáljuk. A vizsgálat módszere a már többször alkalmazott panel-regresszió, a következő egyszerű egyenlet alapján:

$$\ln(\text{TFP}_{it}) = \beta_0 + \beta_1 \times \ln(\text{INTER}_{it}) + \nu_i + \varepsilon_{it} \quad (5.21)$$

ahol az INTER_{it} változó helyére az (5.19) vagy (5.20) képletek alapján kiszámolt INTER_SHARE_{it} vagy REL_LINK_{it} változók helyettesíthetők. Az 5.9. táblázat a már ismert

módon tartalmazza a legfontosabb regressziós eredményeket.²⁰ A részletes eredményeket a fejezethez tartozó függelék F18-F21 Táblázatai tartalmazzák.

Gördülő összeg Kooperáció			Gördülő összeg Szabadalomszám		
const	5,616	***	const	5,554	***
REL_LINK	-0,010	**	REL_LINK	-0,052	
Gördülő összeg Kooperáció			Gördülő összeg Szabadalomszám		
const	5,387	***	const	5,420	***
INTER_SHARE	-0,327	**	INTER_SHARE	-0,181	

5.9. táblázat. Regressziós eredmények korrigált magyarázó változókkal, eredményváltozó: régiós TFP

Az eredményekből látható, hogy a külső kapcsolatok aránya negatív kapcsolatban áll a TFP-vel, bár ez a kapcsolat nem minden esetben szignifikáns. Amennyiben a kapcsolatok intenzitását a kooperációs intenzitással mérjük, úgy szignifikáns negatív kapcsolatot találunk, függetlenül a kapcsolati mutatók számításának módjától. Ha a kapcsolati súlymátrix a szabadalomszám alapján kerül meghatározásra, úgy a TFP és a külső kapcsolatok szerepe között negatív, de nem szignifikáns kapcsolatot találunk. Mindezek alapján azt a következtetést vonhatjuk le, hogy a sejtésünk szerint jelenlévő negatív kapcsolat a régiók TFP értéke és a külső kapcsolatok szerepe között valóban létezik: az alacsonyabb TFP-vel jellemezhető régiók tipikusan nagyobb mértékben támaszkodnak külső kapcsolatokra. Fontos kiemelni, hogy a most talált negatív összefüggés nem a hálózati kapcsolatokon keresztül hozzáférhető tudásra, hanem a kapcsolatok számára (intenzitására) vonatkozik, ebben az értelemben tehát nem egyszerűen a már feltárt negatív kapcsolat alternatív mutatószámokkal történő újbóli felfedezéséről van szó. Az eredményeket tekintve semmilyen különbség nincsen az egyszerű és a gördülő összegzéssel számolt szabadalmi állományok esetén a kapott eredmények között. Ennek az az egyszerű oka, hogy jelen esetben nem a szabadalmi állomány, hanem csupán a hálózati kapcsolatok szerepelnek a magyarázó változók között, így irreleváns a két állomány-képző módszer megkülönböztetése.

Mindezek alapján azt a következtetést vonhatjuk le, hogy amennyiben a külső kapcsolatok számával korrigáljuk az első, (5.18) regressziót, úgy a külső tudás és a TFP közötti kapcsolat iránya megváltozhat. Ehhez egyszerűen kiszámítjuk valamennyi régió külső kapcsolatainak számát. Felhasználva a korábban már alkalmazott jelöléseket:

$$\text{INTER_REG}_{it} = \sum_{j=1}^N r_{ij}^t - r_{ii}^t \quad (5.22)$$

Majd ezen új változó segítségével képezzük az alábbi normalizált változót:

²⁰Itt csak a súlyozott kapcsolati mátrix és gördülő összegzéssel számolt szabadalomszám alapján végzett elemzések eredményeit közöljük.

$$X_{it} = \frac{\text{NETWORK}_{it}}{\text{INTER_REG}_{it}} \quad (5.23)$$

Az így kapott X_{it} az i régió külső tudásának a hálózati kapcsolatainak számához (intenzitásához) viszonyított arányát mutatja a t időszakban. Ezzel a módszerrel azonban csupán azt tudjuk kontrollálni, hogy az alacsonyabb TFP-vel jellemezhető régiók tipikusan több külső kapcsolattal rendelkeznek, mint a magasabb TFP-jű régiók. Azt a problémát még nem kezeljük, hogy az alacsonyabb TFP-jű régiók tipikusan azon régiókhoz kapcsolódnak, amelyek nagyobb tudásbázissal rendelkeznek, vagyis, hogy a periférikus régiók inkább a központi régiókhoz csatlakoznak. Ez azt jelenti, hogy a külső kapcsolatok és a TFP értékek közötti negatív kapcsolat nem csupán a külső kapcsolatok nagyobb számából fakad, hanem abból is, hogy a partner-régiók jellemzően magasabb tudásállománnyal bírnak. Az (5.23) egyenlet által megadott mutatószám azt mutatja meg, hogy mekkora az egy kapcsolaton (kapcsolati egységen, ha súlyozott kapcsolati mátrixszal dolgozunk) keresztül kintről érkező tudás nagysága. Az alacsonyabb TFP-jű régiókban azonban az előbb leírt tendencia miatt az egy ilyen kapcsolaton keresztül beáramló tudás is tipikusan magasabb lesz, mivel a partnerek jellemzően nagyobb tudás-állománnyal rendelkeznek. A kapcsolatszám mellett ez a jelenleg is hozzájárul az (5.18) regresszióban tapasztalt negatív együttthatóhoz a külső tudás tekintetében.

Ezt a fajta torzítást közvetlenül a TFP értékeket érintő korrekcióval szűrhetjük ki. Kézenfekvő lenne a TFP értékeket is a külső kapcsolatokkal normalizálni. Ez a megoldás azonban félrevezető, hiszen így a megbecsült regressziós egyenlet mindkét oldalát ugyanazokkal az értékekkel osztjuk végig, és így a két oldal között adódó pozitív korreláció garantált, de nem feltétlenül mutat valódi összefüggést. Egy további lehetőség, hogy a TFP értékeket nem a külső kapcsolatok, hanem a belső, vagyis a régió belüli kapcsolati intenzitás nagyságával korrigáljuk. Az így kapott mutató egyszerűen azt méri, hogy egy régió TFP értéke mennyiben tér el belső kapcsolati intenzitás által indokolttól:

$$Y_{it} = \frac{\text{TFP}_{it}}{\text{INTRA_REG}_{it}} \quad (5.24)$$

ahol

$$\text{INTRA_REG}_{it} = r_{ii}^t \quad (5.25)$$

A (5.24) összefüggésben Y_{it} magasabb értéket mutat egy olyan régió esetén, ahol a belső kapcsolati intenzitáshoz viszonyítva a TFP értéke magasabb, míg alacsonyabbat, ahol a helyzet fordított. Kimutatható, hogy a belső kapcsolatok abszolút száma és a TFP között enyhe pozitív irányú kapcsolat található (a korrelációs együtttható 0,52 körül mozog): ez az összefüggés abból a tényből fakad, hogy a magasabb TFP értékkel együtt jár a magasabb szabadalmi aktivitás, ami értelemszerűen növeli akár a régió belüli, akár az azon kívüli kapcsolatok számát. Így tehát az (5.24) mutató felfogható úgy is, mint egy olyan mutató,

amely a TFP értékek extra volatilitását ragadja meg: a számláló és a nevező közötti pozitív kapcsolat egyfajta tendenciát ragad meg a TFP és a szabadalmi tevékenység között. Ennek megfelelően Y_{it} magasabb értékei azt mutatják, ha egy régió TFP értéke ebből a tendenciából pozitív irányban tűnik ki, míg az alacsonyabb értékek a fordított esetben adódnak. Ezek alapján az (5.24) mutatószám segítségével lehetőségünk van arra, hogy a TFP értékek extra volatilitását magyarázzuk meg a normalizált magyarázó változók segítségével.²¹

A fentiek alapján a következő regressziós egyenletet állítjuk fel:

$$\ln(Y_{it}) = \beta_0 + \beta_1 \times \ln(\text{PAT_STOCK}_{it}) + \beta_2 \times \ln(X_{it}) + \nu_i + \varepsilon_{it} \quad (5.26)$$

Az eddigiekhez hasonlóan az (5.26) egyenlet többféle tartalommal is feltölthető, attól függően, hogy az egyes mutatókat milyen módszer szerint számítjuk ki. Az 5.10. táblázatban a high-tech szektorra vonatkozó mutatókra kapott eredményeket mutatjuk be a tudásállomány és a kapcsolati intenzitás két-két számítási módja szerint (hasonlóan az 5.9. táblázat struktúrájához). A táblázat csak az összefoglaló adatokat tartalmazza, a részletes eredmények a fejezethez tartozó függelék F22-F25 táblázataiban találhatóak.

Egyszerű összeg Kooperáció			Egyszerű összeg Szabadalomszám		
const	-0,097		const	0,285	**
HTPAT	0,073	***	HTPAT	0,103	***
X	0,467	***	X	0,205	***
Gördülő összeg Kooperáció			Gördülő összeg Szabadalomszám		
const	-0,436	**	const	0,149	
HTPAT	0,163	***	HTPAT	0,036	
X	0,612	***	X	0,488	***

5.10. táblázat. Regressziós eredmények korigált magyarázó változókkal, eredményváltozó: korigált régiós TFP

Az 5.10. táblázatban jól látható, hogy a korigált változók között pozitív, szignifikáns kapcsolatot találunk, valamennyi vizsgált esetben, bár a koefficiensek értéke különböző. A kapott kedvező eredmények interpretálása azonban nem triviális. Az, hogy a korigált TFP értékek és a korigált külső tudás között szignifikáns pozitív kapcsolat fedezhető fel, a korigált értékek tényleges korrelációja mellett abból a tényből is fakadhat, hogy az eredeti, (5.18) regressziós egyenlet jobb oldalán található NETWORK_{it} mutatót és a bal oldali TFP_{it} értékeket két olyan adatsorral osztottuk végig (INTER_REG_{it} és INTRA_REG_{it}), amelyek nagyon szoros korrelációt mutatnak. A korrelációs együtthatók értéke (a mutatók számítási módjától függően) 0,78 és 0,84 között mozog. Így a fenti pozitív irányú összefüggés származhat pusztán ebből az együttmozgásból.

²¹Fontos megjegyeznünk azt is, hogy az itt használt INTER_REG_{it} változó nem azonos a korábban alkalmazott REL_LINK_{it} vagy INTER_SHARE_{it} változókkal, mivel az utóbbiak a külső kapcsolatok relatív arányát mérték, míg az előbbi a külső kapcsolatok abszolút volumenét.

Egy további lehetőség maradt, amelynek alkalmazásához pusztán az a felvetés szükséges, hogy az általunk vizsgált adatbázisban, és elsősorban a TFP értékekben nagyfokú útfüggőség van jelen. Ez azt jelenti, hogy a korábban már felvázolt tendencia, mely szerint az alacsony TFP-jű régiók a magas TFP-jű régiókhöz csatlakoznak és fordítva, egyfajta evolúciós folyamat eredménye. Így a TFP szintek közvetlen alkalmazása a regressziós egyenletekben mindenképpen tartalmazza az ebből fakadó torzításokat. Érdeemes lehet ennek megfelelően a kérdést másként feltenni: hat-e valamilyen módon a külső tudás a TFP változására? A TFP állományi értékei helyett ebben az esetben a TFP változását (növekedési rátáját) szerepeltetjük a regressziós egyenlet bal oldalán, így kiszűrve a TFP állományokban tapasztalható útfüggőséget.

A növekedési ráták alkalmazása esetén azonban egy módszertani váltásra is szükségünk van. Eddig az egyedi évek adataira panel-regressziós technikát alkalmaztunk, ugyanakkor a növekedési ráták esetén a rövid távú üzleti ciklusok kiszűrése miatt az egyedi évekre illesztett panel-regresszió túlzott zajjal járna. Így a rendelkezésre álló három év adatait átlagolva egyszerű OLS regressziós technikát alkalmazva vizsgáljuk a külső és belső tudás, valamint a TFP változása közötti kapcsolatot. A regressziós egyenlet a következő:

$$g_TFP_i = \beta_0 + \beta_1 \times AV_PAT_STOCK_i + \beta_2 \times AV_NETWORK_i + \varepsilon_i \quad (5.27)$$

A fent leírtaknak megfelelően g_TFP_i az i régió éves TFP növekedési rátáinak átlaga, $AV_PAT_STOCK_i$ az i régió éves szabadalmi állományai logaritmusának átlaga, $AV_NETWORK_i$ pedig a külső tudás éves állományai logaritmusának átlaga. Fontos kiemelnünk, hogy a külső tudást az (5.27) regresszióban már a korrigált módszer alapján számítjuk ki, azaz az $AV_NETWORK_i$ mutató a külső tudás külső kapcsolatokkal normált értékét jelöli. A korábbiakhoz hasonlóan itt is lehetőség van a változók különböző módszerrel történő kiszámítására. Az összefoglaló eredményeket mutatja az 5.11. táblázat, a részletes statisztikák az eddigieknek megfelelően a fejezethez tartozó függelék F26-F29 táblázataiban találhatóak.

Gördülő összeg Kooperáció		Gördülő összeg Kooperáció	
const	0,188	const	-0,186
AV_PATSTOCK	-0,094		
AV_NETWORK	0,103 *	AV_NETWORK	0,123 **
Gördülő összeg Szabadalomszám		Gördülő összeg Szabadalomszám	
Const	0,175	const	-0,203
AV_PATSTOCK	-0,093		
AV_NETWORK	0,107 *	AV_NETWORK	0,129 **

5.11. táblázat. Regressziós eredmények növekedési rátákkal

A táblázat azt mutatja, hogy a (5.27) regresszió alapján gyengén szignifikáns, de pozitív irányú kapcsolatot találunk a külső tudás és a TFP növekedése között. Ugyanakkor a belső tudásállomány pozitív hatása nem mutatható ki. Ez utóbbi jelenség miatt elvégeztünk

olyan regressziós vizsgálatokat is, amelyeknél csak a külső tudást szerepeltettük a jobb oldalon magyarázó változóként. Ebben az esetben már erősebb kapcsolatot kapunk, a becslt koefficiens értéke azonban nem változik számottevően.

A kedvező előjelű és gyengén szignifikánsnak mutató eredmények ellenére fontos azt is látnunk, hogy a becslt regressziós egyenletek magyarázóereje rendkívül alacsony. Az R^2 értékek 0,05 és 0,07 között mozognak, ami a kapott eredményeket meglehetősen bizonytalaná teszi. A csekély magyarázóerő azonban annak is felróható, hogy a TFP növekedési ütemének magyarázatakor számos fontos változót kihagytunk, amelyek a gazdasági növekedést (a TFP növekedését) magyarázhatják. Egy szélesebb körű vizsgálat addicionális adatok bevonásával fényt deríthet arra, hogy a külső tudás és a TFP növekedése között valóban megtalálható-e az imént talált pozitív összefüggés. További forrása a nagyfokú bizonytalanságnak a rendelkezésünkre álló idősor rövidsége. Ugyan a három év értékeinek átlagolásával nyert adatok a TFP növekedésében tapasztalható volatilitást csökkentik, de szélesebb időhorizont mellett minden bizonnyal megbízhatóbb eredményeket kaphatunk. Sajnos a rendelkezésünkre álló adatbázis, a korábban már leírt okok miatt csak ennek a három évnek a vizsgálatát teszi lehetővé.

Összefoglalva, a régiók külső tudása és a TFP között első megközelítésben feltárt negatív összefüggést sikerült legalább annyira árnyalnunk, hogy a 3. fejezet modelljében feltételezett pozitív irányú kapcsolat nem tűnik valószínűtlennek. Ugyanakkor a következő fejezet-pontban azt fogjuk megvizsgálni, hogy az empirikusan feltárt negatív összefüggés milyen körülmények között jöhet létre a szimulációs modellben. Mint majd látni fogjuk, a negatív kapcsolat lehetséges, sőt, a szimulációs eredmények a negatív kapcsolatot kialakító hálózati struktúra tekintetében egybevágóan az empirikus tapasztalatokkal.

5.2.2.5. Negatív koefficiensek a szimulációs modellben

Az előző szakaszban kimutattuk, hogy a korábban becslt regionális TFP értékek valamint a külső tudásállomány között szignifikáns negatív kapcsolat fedezhető fel. Az előző szakasz jelentős részében azért tettünk erőfeszítéseket, hogy kimutassuk a TFP és a külső tudás közötti pozitív irányú kapcsolat létét az adatsorok alkalmas korrekciójával úgy, hogy az eredményeket torzító hatásokat kiszűrjük. Ugyanakkor lehetőség nyílik egy másik módszer alkalmazására is, nevezetesen arra, hogy az empirikusan megfigyelhető negatív kapcsolatot az általunk alkalmazott modellben is megkeressük.

A 3. fejezet modelljében az alábbi, már többször hivatkozott tudás-aggregátort használtuk:

$$K_i = k_i + \left[\sum_{j=1}^N \alpha_{ij} (\theta k_j)^\rho \right]^{\frac{1}{\rho}} \quad (5.1)$$

A fenti összefüggésbe $\rho = 1$ -et helyettesítve az előző szakaszban azt kaptuk, hogy az általunk használt adatokon a régiók külső tudása (a jobb oldali zárójeles kifejezés) negatív

kapcsolatban áll a TFP-vel (bal oldal). Érdeemes feltenni a kérdést, hogy a 3. fejezet modelljében megtalálható-e ez a jelenség, és ha igen, mely paraméter-értékek mellett. Az alábbiakban egy ilyen szimulációs vizsgálatot végzünk el, melynek menete a következő.

Első lépésben a vizsgált hálózat paramétereit rögzítjük. Hogy az empirikus hálózattal összevethető eredményeket kapjunk, a hálózat csomópontjainak számát 96-ra állítjuk be, valamint az átlagos fokszámot 15-re (ez utóbbi értéket az empirikus hálózat átlagos fokszámának időbeli átlagaként kaptuk). A hálózat alap-paramétereinek meghatározása után a 3. fejezetben ismertetett két hálózati modell (Watts-Strogatz modell vagy módosított Barabási-Albert modell) valamelyikével kialakítjuk a megfelelő paraméterekkel rendelkező hálózatot. Így rendelkezésünkre áll az (5.1) összefüggésbe helyettesítendő, a_{ij} elemeket tartalmazó \mathbf{A} kapcsolati mátrix.

A K_i értékek kiszámításához ezen felül (értelemszerűen a θ és ρ paraméterek mellett) a régiók belső tudásának, a k_i értékek meghatározására is szükség van. Ezeket az értékeket szintén az empirikus értékeket figyelembe véve az alábbi módon generáljuk. Minthogy a régiók belső tudásának logaritmus ($\ln(\text{PAT}_{it})$) normális eloszlást követ, egyszerűen generálhatunk egy 96 elemű vektort, amelynek elemei szintén normális eloszlást követnek. Ezt követően egyszerű exponenciális transzformációval kapjuk az (5.1) összefüggéshez szükséges k_i értékeket.

Az \mathbf{A} mátrix és \mathbf{k} vektor segítségével, adott θ és ρ paraméterek mellett az (5.1) összefüggés megadja a modell K_i TFP értékeit. Ezt követően mindössze arra van szükségünk, hogy az így kiszámított K_i értékek és a külső tudás, vagyis az \mathbf{Ak} szorzat közötti összefüggést megvizsgáljuk. Fontos kiemelnünk, hogy a K_i értékeket az (5.1) egyenlet alapján ρ tetszőleges értéke mellett határozzuk meg, azonban a TFP értékek és a külső tudás kapcsolatát, összhangban az empirikus vizsgálatunkkal $\rho = 1$ értékét feltételezve vizsgáljuk. Egy utolsó lépésként a külső tudásszintet, akár csak az empirikus vizsgálatban, a régiók kapcsolatszámával normáljuk. Így a következő mutatót kapjuk:

$$s_i = \frac{\sum_{j=1}^N a_{ij} k_j}{\sum_{j=1}^N a_{ij}} \quad (5.28)$$


Az így kiszámolt TFP értékek és a külső tudás közötti kapcsolatot egyszerű regressziószámítással vizsgáljuk meg, az alábbi regressziós függvényt felhasználva:

$$K_i = \beta_0 + \beta_1 s_i + \varepsilon_i \quad (5.29)$$

A regressziót lefuttatva feljegyezzük a β_1 koefficiens értékét, majd a fenti eljárást különböző θ és ρ paraméterek mellett, valamint a hálózatok különböző típusai mellett elvégezve feltárhatjuk, hogy a 3. fejezet modelljében felfedezhető-e az empirikusan kimutatott negatív irányú kapcsolat.


A fenti szimulációkat az alábbi kombinációkban végeztük el. A 3. fejezetben bemutatott Watts-Strogatz modell p paraméterének valamennyi értékére (0,01-os lépésközökkel), illet-

ve a módosított Barabási-Albert modell r paraméterének valamennyi értéke mellett (0,01-os lépésközökkel). Mindkét modell esetén θ és ρ 9 különböző kombinációjára végeztük el a szimulációt: $\theta = 0,2$, $\theta = 0,5$ és $\theta = 0,8$, valamint $\rho = 0,5$, $\rho = 1,0$ és $\rho = 1,5$ értékekre. A paraméterek valamennyi kombinációjára 1.000 futtatást végeztünk el, és az 1.000 futtatásra kapott β_1 értékek átlagát számítottuk ki. Az 5.7-5.9. ábrák mutatják a fenti szimulációs futtatások eredményét a Watts-Strogatz modell esetén.




5.7. ábra. A külső tudásmennyiség becsült regressziós együtthatója a Watts-Strogatz modellben, $\rho = 0,5$ esetén

A vízszintes tengelyen a Watts-Strogatz modell p paramétere változik 0 és 1 között, a függőleges tengelyen pedig a regressziós egyenes β_1 paramétere kerül felmérésre. A három ábra ρ különböző értékei mellett mutatja a regressziós koefficiens alakulását és minden ábrán θ három különböző értéke mellett adjuk meg az eredményeket. A legfontosabb eredmény, hogy a Watts-Strogatz modell esetén nem találunk olyan paraméter-kombinációt, amelyre a vizsgált β_1 paraméter negatív értéket venne fel, vagyis a hálózat csomópontjainak TFP értéke valamint a csomópontok külső tudása között negatív kapcsolatot találnánk. ρ kisebb értékeire (5.7. és 5.8. ábrák) a koefficiens csökkenő tendenciát mutat a véletlen hálózatok (p magasabb értékei) felé. A spillover paraméter értéke a regressziós koefficiens abszolút értékére van hatással: a magasabb spillover érték meredekebb regressziós egyenest eredményez, ami azt a triviális összefüggést mutatja, hogy annál nagyobb mértékben járul hozzá a külső tudás a csomópontok TFP értékéhez, minél magasabb a paraméter értéke – ez az eredmény logikusan következik a tudás-aggregátor definíciójából. Ha θ értékét rögzítjük, ρ szintén hatással van a koefficiens abszolút értékére: ρ magasabb értékeire a koefficiens értéke tipikusan alacsonyabb, ami azt az összefüggést jelzi, hogy a helyettesíthetőség növekedése a külső tudás addicionális értékét csökkenti, így ρ növekedése a spillover paraméter csökkenésével analóg hatású.




5.8. ábra. A külső tudásmennyiség becsült regressziós együtthatója a Watts-Strogatz modellben, $\rho = 1,0$ esetén




5.9. ábra. A külső tudásmennyiség becsült regressziós együtthatója a Watts-Strogatz modellben, $\rho = 1,5$ esetén

Az 5.10-5.12 ábrák mutatják a Barabási-Albert modellre elvégzett vizsgálatok eredményét. Akárcsak a Watts-Strogatz modell esetén, most is ρ és θ három-három különböző értékére futtattuk le a szimulációt. Az ábrák az előbbiekhöz hasonlóan most is 1.000 futtatás átlagát mutatják minden egyes r értékre.




5.10. ábra. A külső tudásmennyiség becsült regressziós együtthatója a módosított Barabási-Albert modellben, $\rho = 0,5$ esetén

Az ábrákon jól látható, hogy a Barabási-Albert modell módosított változatában a β_1 koefficiens negatív értékeket is felvesz. Sőt, ezek a negatív értékek tipikusan az r paraméter magas értékeire jellemzőek, azaz azokban az esetekben, amikor a hálózat egyre jobban megközelíti a szélsőséges skálafüggetlenséget. Ez a jelenség ρ és θ szinte valamennyi értékére jellemző, ugyanakkor némi variáció mutatkozik a tendenciákban e két paraméter függvényében. A legszélsőségesebb eseteket $\rho = 0,5$ mellett találjuk. Ekkor a spillover paraméter alacsony értékeinél nem figyelhető meg a negatív koefficiens jelenléte, ugyanakkor θ magasabb értékei mellett már abszolút értékben nagyon magas koefficienseket kapunk. ρ magasabb értékeinél a negatív koefficiensek r valamennyi értéke mellett abszolút értékben kisebbek, míg a $\rho = 1$ eset egyfajta átmenetnek tekinthető. Ha a spillover paraméter parciális hatását vizsgáljuk, akkor azt találjuk, hogy r alacsony és magas értékeire is abszolút értékben nagyobb koefficienset kapunk, ha θ értéke magasabb. Vagyis, a nagyobb intenzitású spillover értelemszerűen a külső tudás és a TFP közötti erősebb kapcsolatot eredményez, függetlenül attól, hogy ez a kapcsolat pozitív vagy negatív irányú.



5.11. ábra. A külső tudásmennyiség becsült regressziós együtthatója a módosított Barabási-Albert modellben, $\rho = 1, 0$ esetén



5.12. ábra. A külső tudásmennyiség becsült regressziós együtthatója a módosított Barabási-Albert modellben, $\rho = 1, 50$ esetén

Összefoglalva a fenti tapasztalatokat, a következőket állapíthatjuk meg. Ugyan a 3. fejezet modelljében a gazdasági aktorok TFP értéke és az aktorok külső tudása között pozitív definíciós kapcsolatot állítottunk fel, a hálózatok struktúrájától függően ez a kapcsolat végül megfordulhat: a magasabb TFP értékhez alacsony külső tudás, míg az alacsony TFP értékhez alacsony külső tudás társul. Ez az eredmény egyáltalán nem meglepő, hiszen előfordulhat, hogy a kis termelékenységű régiók csatlakoznak a centrális, nagy tudással rendelkező régiókhoz és fordítva, a centrális, magas TFP-vel rendelkező régiók az alacsony tudású, alacsony TFP-vel rendelkező régiókhoz csatlakoznak. A szimulációs eredmények azt is megmutatják, hogy milyen specifikus hálózati struktúra mellett alakulhat ki ez a jelenség: amennyiben a hálózat elegendően erős centrum-periféria tulajdonságokat mutat, azaz valóban teljesül, hogy a centrális szereplők inkább periferikus (és így kis tudásállománnyal, valamint kis TFP értékkel jellemezhető) szereplőkhöz csatlakoznak és fordítva – más szavakkal abban az esetben, ha a hálózat erősen skálafüggetlen.

Mindezek alapján látható, hogy a TFP értékek és a külső tudás között a fejezet során feltárt negatív kapcsolat nem jelenti azt, hogy a korábban bemutatott modell irreleváns feltételezésen alapszik, amennyiben pozitív irányú definíciót használ a TFP és a külső tudás között. Mindössze arról van szó, hogy az e fejezetben vizsgált adatbázis esetén a feltárt hálózati struktúra jellemzően skálafüggetlen. A 3. fejezet modellje ugyanakkor ettől eltérő hálózati struktúrákat is képes kezelni.

6. fejezet

Kísérlet a hálózati struktúra és a gazdasági teljesítmény közötti kapcsolat empirikus elemzésére

A 3. fejezetben bemutatott és a 4. fejezetben elemzett modell egyik fontos következtetése volt, hogy a hálózati struktúra és a gazdasági teljesítmény között szoros összefüggés található. Ebben a fejezetben egy olyan módszert mutatok be, amely alapján e kapcsolat empirikus nyomaira bukkanhatunk. A módszer alkalmazása biztató eredményekkel jár, ugyanakkor a kapcsolat korrekt elemzése további feladatként a kutatómunka folytatását igényli. A fejezet első részében bemutatjuk a felhasznált adatbázist, a második részben az adatbázis alapján néhány leíró elemzésre kerül sor, majd a harmadik részben a gazdasági teljesítmény és a hálózati struktúra közötti kapcsolat vizsgálatának empirikus eredményit ismertetjük.

6.1. A felhasznált adatok

A vizsgálathoz értelemszerűen kétféle adatra van szükségünk: egyrészt a hálózati struktúrát leíró adatbázisra, másrészt pedig a gazdasági teljesítményt leíró adatokra. Az alábbiakban ezeket az adatforrásokat mutatjuk be.

6.1.1. Gazdasági teljesítmény

Valóban a gazdasági teljesítményt leíró adatbázis kapcsán egyszerű dolgunk van, mivel ezek az adatok többnyire rendelkezésre állnak más forrásokból. Esetünkben a Pennsylvanai Egyetem által publikált és rendszeresen frissített, a világ országainak makrogazdasági adatait tartalmazó Penn World Table adatbázis szolgál a gazdasági teljesítményt leíró adatbázis forrásául (Heston és szerzőtársai, 2009). Az adatbázisból mindössze két adatsort

használunk fel: a reál GDP egy főre eső értékének idősorait a vizsgálatunk tárgyát képező országokra, valamint ebből egyszerűen számítható módon az egy főre jutó reál GDP növekedési ütemét.

6.1.2. Hálózati struktúra

A hálózati struktúra vizsgálatához a gazdasági teljesítménnyel szemben nem állnak rendelkezésre kész adatok, így az adatbázisnak ezt a részét más adatokra építve kell létrehozni. A 3. fejezet modelljének kétfajta interpretációja lehet: az egyik értelmezés szerint a tudáshálózat csomópontjait reprezentáló gazdasági egységek vállalatok, a másik szerint pedig területi egységek, régiók.¹ Az első interpretáció alapján történő vizsgálatához egyelőre nem állnak rendelkezésre megfelelő adatok, de az itt bemutatandó, régiós szintű elemzés módszertanára építve már folyamatban van egy, vállalati szintű tudáshálózati adatbázis létrehozása. Mindazonáltal e helyen csak a második interpretáció, vagyis a régiós hálózatok vizsgálatára van lehetőség.

A tudáshálózati adatok felépítéséhez az 5. fejezetben már bemutatott módszert használok fel, csupán más szinten. Az alapul szolgáló adatbázis is más: a korábban használt, a Pécsi Tudományegyetem Közgazdaságtudományi Karán összeállított adatbázis NUTS2 szinten tartalmazott regionális bontást. Jelen esetben azonban az a cél, hogy ettől részletesebb szinten vizsgáljuk a hálózati struktúrát. Az alapul szolgáló adatbázis az OECD által összeállított REGPAT elnevezésű szabadalmi adatbázis, amely a szabadalmak regionális besorolását NUTS3 szinten tartalmazza (OECD, 2009). Az adatbázis az Európai Szabadalmi Hivatalhoz (EPO), az Egyesült Államok Szabadalmi Hivatalához (USPTO) valamint Japán Szabadalmi Hivatalhoz (JPO) benyújtott szabadalmakat regionalizálja mind a szabadalmat benyújtó, mind pedig a feltalálók szerint. E lehetőségek közül itt csupán a feltalálók szerinti regionalizációt használjuk fel.

Az OECD adatbázisából számunkra releváns információ csupán az alábbi: valamennyi szabadalomhoz, melyet a szabadalom sorszáma azonosít, az adatbázis hozzárendeli a feltalálók címének megfelelő NUTS 3 szintű régió kódokat. Ezek alapján az információk alapján az 5. fejezetben ismertetett módszer segítségével könnyen felépíthetünk egy olyan adatbázist, amely a NUTS 3 szintű régiók közötti feltalálói kapcsolatokat tartalmazza. Fontos kiemelni, hogy az 5. fejezetben használt adatbázissal szemben (ahol a hálózati kapcsolatokat csak a high-tech szektorra tudtuk felhasználni), ebben a vizsgálatban az összes szabadalmi együttműködésről rendelkezésünkre állnak információk. A felépített szabadalmi együttműködési hálózatok tehát a gazdasági tevékenység teljes spektrumát lefedik.² Mivel a rendelkezésünkre álló hálózati adatbázis így (a szabadalmazási hajlandóság szektorok közötti eltérésekből fakadó torzításoktól eltekintve) a teljes gazdaságot fedi át, így a GDP adatok esetén

¹A két értelmezés közötti kapcsolatot az előző fejezet elején részletesen tárgyaltuk.

²Nyilván figyelembe kell azt is vennünk, hogy a szabadalmazási tevékenység (vagy szabadalmazási hajlandóság) jelentős eltéréseket mutat az egyes szektorokban.

módosítások nélkül használhatjuk a Penn World Table által közvetlenül közölt egy főre jutó reál GDP adatokat.

Egyrészt annak érdekében, hogy az elemzés kezelhető keretek között maradjon, másrészt pedig az adatfeldolgozás kapcsán felmerülő számítástechnikai kapacitás-korlátok okán, az elemzést a 27 Európai Unió tagországra végeztük el. Ez összesen 1.330 NUTS 3 szintű régiót jelent. A nyers hálózati adatbázis így egy olyan kapcsolati mátrix, amely 1.330 sorral és oszloppal rendelkezik. A hálózati struktúra és a gazdasági teljesítmény összeméréséhez azonban alegységeket kell képeznünk, amelyekben belül a hálózati struktúra vizsgálható, ugyanakkor a gazdasági teljesítmény összehasonlítható. Ezen alegységeknek az országokat választjuk, így az országokon belüli hálózati struktúrát vizsgáljuk és vetjük össze az országok gazdasági teljesítményével. Az eredeti, 1.330 elemű hálózatból az országos hálózatokat egyszerűen úgy képezzük, hogy az adott ország régiói közötti kapcsolatokat vesszük csak figyelembe, az országhatárokon átívelő kapcsolatokat nem vizsgáljuk. Ez az eljárás konzisztens a céljainkkal, hiszen a belső hálózati struktúra hatását kívánjuk vizsgálni.³

Módszertani szempontból ez a redukció a következőt jelenti. Legyen a már ismert jelöléssel \mathbf{R} az eredeti, 1.330 régiót tartalmazó kapcsolati mátrix, \mathbf{R}^c pedig a c ország belső kapcsolati mátrixa. Jelölje D^c az i régió indexek halmazának azon részhalmazát, amely régióindexek a c országhoz tartoznak. Ekkor igaz, hogy

$$r_{ij}^c = \begin{cases} r_{ij} & | i, j \in D^c \\ 0 & | i, j \notin D^c \end{cases} \quad (6.1)$$

ahol r_{ij}^c és r_{ij} rendre az \mathbf{R}^c és \mathbf{R} mátrixok általános elemeit jelölik. Természetesen az így kapott \mathbf{R}^c ország-szintű kapcsolati mátrixok továbbra is 1.330 sorból és oszlopból állnak, azonban egyszerűen redukálhatóak olyan mátrixra, ahol a sorok és oszlopok száma megegyezik a c ország NUTS3 régióinak számával. Ehhez egyszerűen el kell hagynunk azon irreleváns sorokat és oszlopokat, amelyek kizárólag nullákat tartalmaznak. Mivel a két típusú (nem redukált és redukált) országos szintű kapcsolati mátrix között nincsen lényeges különbség, ezért külön jelölést sem alkalmazunk.

A kapcsolati mátrixok alapján a hálózat strukturális mutatói már könnyen kiszámíthatóak. A 3. fejezet modelljében két dimenzió mentén kezeltük a hálózatokat. Az egyik dimenziót a Watts-Strogatz modell szolgáltatta, ahol két releváns strukturális mutatót alkalmaztunk: az átlagos klaszterezettséget és az átlagos elérési úthosszt. A másik dimenziót a módosított Barabási-Albert modell mentén értelmeztük és az itt alkalmazott strukturális mutató a csomópontok fokszám-eloszlását leíró eloszlásfüggvény (hatványfüggvény) paramétere (kitevője) volt. Így a hálózati struktúra leírásához e három mutató kiszámítására van szükség. A mutatók kiszámításának módját a 3.4.1. pontban részletesen ismertettük, itt nem térünk ki rá újból, ugyanakkor némi módszertani kiegészítéssel kell élnünk.

³Maggioni és Uberti (2006) szerint a szabadalmi hálózatok – kevés számú nemzetközi kapcsolattól eltekintve – elsősorban országokon belüli kapcsolatokat jelentenek. Így az ilyen kapcsolatok ignorálása nem jelent nagy torzítást a továbbiakban.

Először, fontos kiemelnünk, hogy az általunk használt klaszterezettségi mutató súlyozatlan hálózatokra alkalmazható, vagyis olyan esetekben, amikor a kapcsolati mátrix bináris. Az \mathbf{R} és ennek következtében az \mathbf{R}^c kapcsolati mátrixok azonban (létrehozásuk módja miatt) súlyozott hálózatok. Így a klaszterezettségi mutató kiszámításánál ezeket a mátrixokat korrigálnunk kell. Ez a korrekció meglehetősen egyszerűen elvégezhető: egyes értékeket kapnak azok a cellák ahol pozitív szám áll, és zérust a többi. Jelölje \mathbf{A}^c a ország bináris kapcsolati mátrixát. Ekkor:

$$a_{ij}^c = \left\{ \begin{array}{l} 1 \mid r_{ij}^c > 0 \\ 0 \mid r_{ij}^c = 0 \end{array} \right\} \quad (6.2)$$

ahol a_{ij}^c az \mathbf{A}^c mátrix általános eleme.

Az átlagos elérési úthossz esetén a súlyozott hálózati kapcsolatok értelmezhetőek: egy nagyobb súlyszám általában rövidebb elérési utat takar, míg egy alacsonyabb érték hosszabbat. Mivel azonban a klaszterezettség és az átlagos elérési út hossza vizsgálatunknak ugyanabban a dimenziójában jelentkezik, mint releváns hálózati mutató, ezért a konzisztencia érdekében az átlagos úthossz kiszámításánál is az \mathbf{A}^c mátrixot használjuk fel. Ez a választás egyben könnyebbséget is jelent, mivel a később bemutatandó arányosítási módszernél ez releváns viszonyítási alapot képez.

Más a helyzet azonban a skálafüggetlenséget mérő hálózati mutató esetén. Ebben az esetben mind a bináris, mind a súlyozott kapcsolati mátrix alkalmazható, különösebb megszorítások nélkül. Kiderül azonban, hogy a súlyozott kapcsolati mátrix esetében a skálafüggetlenség jelenléte sokkal inkább érzékelhető, míg a bináris mátrix esetén kevésbé. Ennek oka, hogy a súlyozott mátrix esetén a centrális csomópontok jelenléte nyilvánvaló, míg ezek a centrális elemek eltűnhetnek, vagy dominanciájuk csökkenhet, ha a nagyszámú kapcsolatot egy másik csomópont felé egyetlen kapcsolati egységgé redukáljuk. Ezen felül a súlyozott hálózatok esetén kapott mutatók megfelelnek annak az általános képnek, amelyet más hálózatok esetén is feltártak, nevezetesen, hogy a skálafüggetlenséget jellemző hatványfüggvény kitevőjének értéke tipikusan -2 és -3 között található (Barabási, 2003). Ezzel szemben a bináris mátrix alkalmazása esetén ezek az értékek a lényegesen alacsonyabb szintű skálafüggetlenséget mutató -1 és 0 közötti tartományba esnek.

A második módszertani megjegyzés a kapcsolat nélküli csomópontokra vonatkozik. Mind az elérési útnál, mind pedig a klaszterezettségnél problémát jelenthet, ha a hálózatba belevesszük azokat a csomópontokat is, amelyek nem rendelkeznek kapcsolattal: ezek a csomópontok az elérési utat irreálisan megnövelik, a klaszterezettséget pedig csökkentik. Ugyanakkor az általunk vizsgált regionális hálózatokra jellemző, hogy (főként a vizsgálat korai éveiben) egyes régiók nem kapcsolódnak a tudás-hálózatához. Éppen ezért fontos, hogy a számunkra releváns, vagyis az összekapcsolt hálózatokon végezzük el az elemzést, figyelmen kívül hagyva a kapcsolat nélküli régiókat. Ez tulajdonképpen ekvivalens azzal, hogy a hálózati mutatók kiszámításához a korábban már említett redukált \mathbf{R}^c kapcsolati mátrixot

(vagy az abból előállított A^c bináris kapcsolati mátrixot) használjuk a mutatók kiszámításához.

Harmadszor pedig arra kell felhívni a figyelmet, hogy miután a fenti három mutatót (átlagos klaszterezettség, átlagos elérési úthossz, skálafüggetlenségi mutató) a hálózati adatok alapján előállítottuk, azok közvetlenül nem összehasonlíthatóak. Ennek oka az, hogy az egyes hálózatok mérete az országok között és időben is változik,⁴ továbbá a hálózatok sűrűsége is változik (tipikusan az figyelhető meg, hogy a sűrűség növekszik, a régiók egyre sűrűbben kooperálnak a szabadalmak tekintetében). Éppen ezért szükséges valamilyen viszonyítási alapot bevezetnünk, amely révén az egyes országok adott időszakban vett hálózati struktúrája összehasonlítható. Ez a közös nevező a hálózati szakirodalomban elterjedten alkalmazott módszertan szerint valamilyen referencia-hálózat hasonló mutatója.

A klaszterezettség és az elérési út esetében az adott országra az adott időszakban (évben) érvényes hálózati méret (csomópont-szám) és átlagos fokszám segítségével egy véletlen hálózatot hozunk létre, amely ugyanekkora mérettel és átlagos fokszámmal rendelkezik. Ennek a referencia-hálózatnak aztán kiszámítjuk a klaszterezettségi mutatóját, valamint az átlagos elérési utat és az általunk megfigyelt empirikus értéket ehhez a referenciaértékhez viszonyítjuk. Így egy összehasonlítható mutatót kapunk, ami e két érték esetében azt jelöli, hogy az általunk megfigyelt hálózat klaszterezettsége és átlagos elérési úthossza hogyan viszonyul egy azonos méretű és sűrűségű véletlen hálózat klaszterezettségéhez és átlagos elérési úthosszához.

A skálafüggetlenség esetén hasonló eljárást alkalmazunk, itt azonban a viszonyítási alapot nem a véletlen hálózat, hanem egy szélsőségesen skálafüggetlen hálózat képezi. A viszonyítási alapul szolgáló skálafüggetlen hálózat felépítéséhez a 3. fejezetben bemutatott módosított Barabási-Albert modellt használjuk fel $r = 1$ paraméterérték mellett, ahol a hálózat mérete és az átlagos fokszám az empirikusan megfigyelt értékek felel meg, a kiindulási hálózat pedig az empirikus hálózat-méret egytized része.⁵

Fontos azt is kiemelni, hogy a véletlenszerűség hatásának minimálisra csökkentése céljából a viszonyítási alapunk nem egyetlen szimulált véletlen vagy skálafüggetlen hálózat megfelelő mutatója, hanem 100 (adott méretre és átlagos fokszámra elvégzett) szimuláció után az egyenként kiszámolt hálózati mutatók átlaga jelenti a referenciapontot. A fentiek alapján tehát rendelkezésre áll egy egyszerű adatbázis, amely az egyes országok esetén tartalmazza a GDP adatokat és a három hálózati mutatót. A továbbiakban ennek az adatbázisnak az elemzését végezzük el.

⁴Természetesen nem lesz több vagy kevesebb régió, viszont ez előző megjegyzésünk alapján belátható, hogy előfordulhat olyan eset, amikor egy korábban kívülálló régió bekerül a hálózatba, vagy pedig egy korábban a hálózatban lévő régió elveszíti kapcsolatait.

⁵Ez utóbbi azt jelenti, hogy egy 30 elemű hálózatnál 3-as maghálózatból indulunk, egy 45 eleműnél 4-es maghálózatból (lefelé kerekítéssel), stb. A 20-nál kisebb méretű hálózatok esetében a minimálisan szükséges két elemű maghálózatból indítjuk a szimulációt.

6.2. Szabadalmi hálózati struktúrák leíró elemzése

Az előző fejezetpontban bemutatott adatbázis lehetővé teszi, hogy a hálózati struktúra és a gazdasági teljesítmény közötti kapcsolatot vizsgáljuk. Mielőtt azonban erre rátérnénk, érdemes a struktúrát leíró mutatószámok elkülönült elemzése. Egyfelől a rendelkezésre álló adatbázisban rejlő lehetőségek minél teljesebb kihasználása végett lehet erre szükség, másrészt pedig a dolgozat elméleti fejezeteiben alkalmazott strukturális mutatók személetes bemutatása is lehetővé válik ezek által. Ennek megfelelően a továbbiakban nem arra teszünk kísérletet, hogy a társadalmi kapcsolatháló elemzés széles módszertanát bemutassam, hanem csupán a korábban már használt (és az előző fejezetpontban is említett) hálózati mutatók vizsgálatát végzem el a rendelkezésre álló adatokon.


Az előző fejezetpontban bemutatott adatbázis NUTS3 régiók szintjén definiálja a hálózat csomópontjait. Az összehasonlító elemzés végett azonban érdemes lehet az egyes országokat külön vizsgálni, így országos szintű hálózatokat kapunk egyfelől, valamint referenciaként használhatjuk a teljes adatbázis 1.330 régióját tartalmazó, a továbbiakban „aggregált” hálózatnak nevezett struktúráját. Az egyes strukturális mutatók leírására itt nem térek ki, azok megtalálhatóak a 3.4.1. fejezetpontban.

6.2.1. Alapvető hálózati mutatók alakulása

Bármely hálózat esetén fontos néhány alapvető paraméter tisztázása. A legfontosabb mindenekelőtt a hálózat mérete, azaz a csomópontok száma, e mellett pedig az átlagos fokszámot szokták általánosan alkalmazni a hálózat leírására (lásd a (3.25) összefüggést). Természetesen a strukturális mutatók nem függetlenek a hálózat méretétől: egy nagyobb hálózatban az átlagos fokszám nagyobb értéket vehet fel (és tipikusan vesz is fel), mint egy kisebb hálózatban. Éppen ezért különböző méretű hálózatok összehasonlításakor lényeges szempont a méret szerint normálni az egyes mutatókat. Ennek megfelelően a 3. fejezetben már említett sűrűség mutatója alkalmazható, amely a hálózat méretét és az átlagos fokszámot egyetlen értékben (egymáshoz viszonyítva) összesíti (lásd a (3.28) összefüggést). A sűrűség mutatója a hálózatban megjelenő kapcsolatok számát viszonyítja az összes lehetséges kapcsolat számához. Annyi kiegészítést kell tennünk, hogy amíg a 3. fejezetben csak bináris hálózatokkal foglalkoztunk, addig most súlyozott hálózattal rendelkezünk. A (3.28) összefüggés azonban könnyen általánosítható úgy, hogy az ott szereplő elemek a kapcsolatok súlyát reprezentálják, mindössze annyit kell tenni, hogy a hálózati kapcsolatok súlyát (amit a „nyers” adatbázis pozitív egész számokkal ábrázol) alkalmasan normalizáljuk 0 és 1 közé eső számokra. A 6.1. ábra az aggregált hálózat sűrűségének alakulását mutatja 1981 és 2001 között.⁶

Az ábrán rendkívül érdekes összefüggés figyelhető meg: a sűrűség először növekszik, majd csökken, a 2000-es évek elejére szinte visszaesik a kezdeti értékre. A tendencia mögött

⁶A 2001 utáni időszak adatai a szabadalmi adatok már említett feldolgozatlansága miatt kerültek ki az elemzésből.




6.1. ábra. Súlyozott sűrűség alakulása az aggregált hálózatban

két magyarázó tényező húzódnak meg. A hálózati sűrűség növekedése ugyanis egyrészt azt mutatja, hogy a régiók közötti kapcsolatok egyre bővülnek, azaz olyan régiók között is létrejön kapcsolat, amelyek között korábban nem létezett összeköttetés, másrészt pedig a kapcsolatok intenzitásának növekedése is a mutató értékének növekedését eredményezi. A kilencvenes évek elejéig tapasztalható növekedés tehát e két tendencia eredőjeként adódik. Hogy a trendet árnyaltabban tekinthessük át, érdemes a hálózati sűrűséget úgy is kiszámítani, hogy a kapcsolatok intenzitását kiszűrjük az elemzésből. Ehhez egyszerűen azt kell tennünk, hogy a sűrűség mutatóját az előző fejezetpontban is bemutatott bináris kapcsolati mátrix felhasználásával számítsuk ki, vagyis eltekintünk a kapcsolatok súlyozásától. A bináris sűrűség alakulása látható a 6.2. ábrán.

Jól látható, hogy bináris kapcsolati mátrix alkalmazása esetén az előző ábrán tapasztalható kilengés nincsen jelen. Ez egyértelműen arra mutat, hogy az előző ábrán látható kilengést a régiók közötti kapcsolatok intenzitásának növekedése, majd ennek az intenzitásnak a csökkenése generálta, miközben az együttműködési hálózatba kapcsolódó régió-párok száma fokozatosan emelkedett. Ez utóbbi egyfelől a szabadalmi tevékenységben résztvevő régiók számának növekedését, másrészt pedig a régiók közötti kapcsolatok számának növekedését jelenti. Vagyis a vizsgált időszak alatt az egyes régiók folyamatosan egyre több régióhoz kapcsolódtak, függetlenül a kapcsolat intenzitásától (6.1. ábra), ugyanakkor a kilencvenes évek elejéig a kapcsolatok intenzitása is folyamatosan emelkedett, ezt követően azonban a kapcsolati intenzitás csökkent, miközben a partnerrégiók száma továbbra is emelkedett.

A továbbiakban az egyes országokra jellemző értékeket tekintjük át. Minthogy ezek vizuális bemutatása a helyzetet inkább nehezítené, mint könnyítené, ezért táblázatos formában mutatom be az egyes mutatók alakulását. A 6.1. táblázat mind a súlyozott, mind pedig a



6.2. ábra. Bináris sűrűség alakulása az aggregált hálózatban

bináris sűrűség mutatója esetén az 1981-es és 2001-es értékeket mutatja be, valamint a változás mértékét a két időszak között.⁷

A táblázatból két dolog tűnik szembe. Egyfelől, hogy a sűrűség-értékek, akár súlyozott akár bináris módszerrel számítjuk, jelentős szóródást mutatnak az országok között, másrészt pedig, hogy az EU27 aggregált hálózatán számított sűrűség értékek jelentősen alacsonyabbak az egyedi értékeknél. Mindkét jelenség mögött a 3. fejezetben már hivatkozott összefüggés található, nevezetesen, hogy a nagyobb méretű hálózatok tipikusan alacsonyabb sűrűséggel jellemezhetőek. Ha megfigyeljük az egyedi sűrűség-értékeket, akkor ez a tendencia jól látható: a legalacsonyabb értékeket Németország, Olaszország, Franciaország és az Egyesült Királyság adják, amelyek hálózati mérete egyben a legnagyobb.⁸ Érdeemes megfigyelni azt is, hogy a súlyozott sűrűség változásai nem tükröznék különösebb mintázatot, nagyjából ugyanolyan arányban találunk növekedést, mint csökkenést különböző mértékekben. Ugyanakkor a bináris sűrűségnél tipikusan három-számjegyű növekedést tapasztalunk, ami egybevág az aggregált hálózatra bemutatott korábbi eredményekkel. Így megállapíthatjuk, hogy az országos hálózatok abszolút értékben nem, de dinamikájukat tekintve reprezentálhatóak az aggregált hálózattal, legalábbis ebben a speciális esetben.

6.2.2. Kis világok

Az alapvető leíró jellegű mutatókon túlmenően fontos annak a tisztázása, hogy a dolgozat elején bevezetett tipikus hálózati struktúrák mennyiben jelennek meg az itt vizsgált hálózatokban. Elsőként a kis világ struktúrák feltérképezésére teszünk kísérletet. Miként azt a

⁷A táblázatban nem szerepelnek azok az országok, amelyekre vonatkozóan a két időszak egyikében vagy mindkét időszakban hiányoznak adatok.

⁸Elegendő csak Németország 430 NUTS3 régiójára gondolnunk, szemben Magyarország 20 ilyen régiójával.


	Súlyozott sűrűség			Bináris sűrűség		
	1981	2001	Változás	1981	2001	Változás
Belgium	0,0209	0,0251	20,15%	0,1829	0,4667	155,11%
Bulgária	0,0345	0,0200	-42,00%	0,3611	0,1619	-55,16%
Dánia	0,0947	0,1302	37,41%	0,5818	0,8333	43,23%
Németország	0,0006	0,0018	210,84%	0,0695	0,2177	213,20%
Írország	0,2400	0,1359	-43,38%	0,4000	0,9167	129,17%
Spanyolország	0,0123	0,0009	-92,42%	0,1667	0,1184	-28,95%
Franciaország	0,0016	0,0058	263,93%	0,1479	0,3696	149,90%
Olaszország	0,0014	0,0015	1,95%	0,0796	0,2083	161,46%
Magyarország	0,0068	0,0134	96,27%	0,2368	0,2762	16,61%
Hollandia	0,0030	0,0030	0,72%	0,2305	0,6354	175,66%
Ausztria	0,0132	0,0197	48,48%	0,1951	0,4270	118,88%
Lengyelország	0,0271	0,0115	-57,53%	0,1930	0,1111	-42,42%
Portugália	1,2000	0,0539	-95,50%	1,0000	0,2088	-79,12%
Románia	0,1481	0,0469	-68,35%	0,6667	0,2667	-60,00%
Finnország	0,0060	0,0104	73,83%	0,1373	0,5895	329,47%
Svédország	0,0363	0,0172	-52,55%	0,4892	0,6494	32,74%
Egyesült Királyság	0,0044	0,0031	-30,29%	0,1069	0,2562	139,66%
EU 27	0,0001	0,0001	22,61%	0,0202	0,0552	173,06%

6.1. táblázat. A sűrűség alakulása egyes európai országokban

3. fejezetben bemutattam, a struktúrák alapvetően két mutató használatával fedezhetőek fel: a klaszterezettségi mutató és az átlagos elérési út segítségével. A klaszterezettség a lokális kapcsolatok dominanciáját méri, míg az átlagos elérési úthossz egy speciális mutatója a hálózat „szélességének” vagyis az egyes csomópontok átlagos távolságának. E mutatók pontos számítási módja megtalálható a 3.4.1. fejezetpontban. Jelen esetben ehhez két kiegészítést kell tennünk, amelyet a 6.1. alfejezetben már részleteztem. Egyfelől a súlyozott kapcsolatok helyett a számítandó mutatók módszertanának megfelelően binarizált kapcsolati mátrixból számítjuk mind a klaszterezettséget, mind pedig az átlagos elérési utak hosszát. Másrészt pedig az így kiszámolt mutatókat az összehasonlíthatóság miatt nem önmagukban, hanem egy referencia-hálózat hasonló értékéhez viszonyítva mutatom be. A referenciaként szolgáló hálózat a kis világok esetében az adott paraméterekkel (méret, átlagos foksám) rendelkező véletlen hálózat.

A kis világ struktúrák jellemzésére egy egyszerű mutatószámot használunk, amely a klaszterezettség és az átlagos elérési út hányadosa. A 3.1. ábra alapján könnyen látható, hogy ez a mutató akkor veszi fel a legmagasabb értékét, amikor a klaszterezettség és az átlagos elérési út közötti relatív különbség a legnagyobb, vagyis amikor a lokális kapcsolatok szerepe még jelentős, de az elérési utak már érdemlegesen rövidebbek a szabályos hálózatban megfigyelhető értékhez képest. Röviden, a fenti hányados akkor vesz fel maximális értéket, amikor a hálózat a leginkább kis világgént írható le. A kis világ mutató alakulását mutatja az aggregált hálózatra a 6.3. ábra.

Az ábráról egyértelműen látható, hogy a vizsgált időszakban az aggregált hálózat egyre kevésbé mutatott kis világ jellegét: mind a klaszterezettség, mind pedig az átlagos elérési út növekedett, hányadosuk azonban csökkent, így egyértelműen mutatva, hogy a hálózati



6.3. ábra. Az aggregált hálózat kis világ jellegének alakulása

struktúra egyre inkább a véletlen hálózat felé tolódott el. A 6.2. táblázatban az előző szakaszhoz hasonlóan összefoglaljuk az egyes országokra kapott eredményeket.

	Kis világ mutató		
	1981	2001	Változás
Belgium	3,0970	1,4850	-52,05%
Bulgária	1,7071	6,7017	292,58%
Dánia	1,0266	1,0987	7,02%
Németország	5,5540	2,2687	-59,15%
Írország	1,1119	0,9759	-12,23%
Spanyolország	1,9968	4,9329	147,04%
Franciaország	3,9470	1,8790	-52,39%
Olaszország	5,3365	2,5509	-52,20%
Magyarország	3,1249	2,7198	-12,96%
Hollandia	2,1856	1,2102	-44,63%
Ausztria	2,3408	1,3993	-40,22%
Lengyelország	2,8550	6,0120	110,58%
Románia	1,4022	4,5063	221,39%
Finnország	1,1167	1,3568	21,50%
Svédország	1,3616	1,1674	-14,27%
Egyesült Királyság	3,6327	2,1454	-40,94%
EU 27	39,2237	11,8320	-69,83%


6.2. táblázat. A kis világ mutató alakulása egyes európai országokban

A táblázat alapján ismét azt látjuk, hogy az egyes országok adatainak átlaga és az aggregált hálózatra kapott értékek nem ekvivalensek, továbbá az egyes országok között jelentős különbségek figyelhetőek meg. Az igaz, hogy az országok többségében, az aggregált hálózathoz hasonlóan, a kis világ struktúra felbomlása figyelhető meg a vizsgált időszak alatt, a változás mértéke ugyanakkor heterogén, sőt, egyes országokban a kis világ struktúra

erősödése figyelhető meg. Ez az erősödés a legerőteljesebb Romániában, Bulgáriában és Spanyolországban.

6.2.3. Skálafüggetlenség

A 2. és 3. fejezetben bemutatott és elemzett másik tipikus hálózati struktúra a skálafüggetlen struktúra volt: az az eset, amikor a hálózat csomópontjainak fokszám-eloszlása aszimmetrikus. Bemutattuk, hogy a skálafüggetlenség mérése a fokszám-eloszlásra illesztett hatványfüggvény kitevőjének becslésével lehetséges. A 6.1. alfejezetben utaltunk arra, hogy a hálózati mutatókat valamilyen referencia-értékhez viszonyítva célszerű vizsgálni. Jelen esetben azonban erre nincsen különösebb szükség, mivel a vizsgált hálózat mérete nem változik lényegesen az elemzett periódus alatt. Ebből kifolyólag a referencia-érték közel azonosnak adódna valamennyi esetben, így mint viszonyításai alap elvesztené jelentőségét. Ennek megfelelően a 6.4. ábrán és a 6.3. táblázatban a skálafüggetlenségi mutató 3.4.1. fejezetpontban megadott számítási módja szerint kapott értékeket, egészen pontosan azok abszolút értékét tüntettük fel.⁹



6.4. ábra. Az aggregált hálózat skálafüggetlenségének alakulása

Az ábrán egy emelkedő trend tapasztalható a skálafüggetlenséget tekintve. Az 1986-os minimális 2,52-es értékről 2000-re 3,01-re nő a skálafüggetlenségi mutató értéke, ami jelentős, 20%-os változást takar. Így tehát azt mondhatjuk, hogy tendenciáját tekintve a vizsgált szabadalmi együttműködési hálózat egyre erősebb skálafüggetlen struktúrával jellemezhető: a centrális régiók szerepe növekszik, amivel a periferikus régiók integráltságuk

⁹Az abszolút érték használata azért indokolt, mert így a negatív mutatók helyett pozitív értékekkel tudunk számolni, másrészt pedig a skálafüggetlenségi mutató abszolút értékének növekedése tükrözi a skálafüggetlenség növekedését.

növelése ellenére (lásd a 6.2. ábrát) nem tudnak lépést tartani.¹⁰ Az országokra lebontott adatok a szokásos módon láthatóak a 6.3. táblázatban.

	Skálafüggetlenség		
	1981	2000	Változás
Belgium	1,1340	1,1689	3,08%
Bulgária	1,1917	1,2719	6,73%
Dánia	0,4954	0,6063	22,38%
Németország	2,3115	2,6091	12,87%
Írország	0,5446	0,4915	-9,75%
Görögország	1,7426	1,4978	-14,04%
Spanyolország	1,8018	1,4419	-19,97%
Franciaország	1,7893	1,7596	-1,66%
Olaszország	1,9668	1,8477	-6,05%
Magyarország	1,0572	1,1463	8,43%
Hollandia	1,3959	1,4382	3,03%
Ausztria	1,3301	1,4489	8,93%
Lengyelország	1,3909	1,4854	6,80%
Portugália	1,5733	1,1302	-28,16%
Románia	1,3493	1,5313	13,48%
Finnország	1,0429	1,2952	24,19%
Svédország	0,8836	1,1380	28,79%
Egyesült Királyság	2,0170	1,9025	-5,68%
EU 27	2,7618	2,9750	7,72%

6.3. táblázat. A skálafüggetlenség alakulása egyes európai országokban


A vizsgált időszakban az egyes országokon belül, néhány kivételtől eltekintve, a skálafüggetlenség növekedése figyelhető meg. A szóródás az egyes országok között továbbra is igen nagy, mind a mutatók értékét, mind pedig a változás mértékét tekintve. Érdekes itt is megfigyelni, hogy akárcsak az eddig vizsgált mutatók esetében, most is igaz az, hogy az aggregált hálózatra (EU27) vonatkozó mutató jelentősen eltér az egyes országokra számolt mutatóktól: az aggregált hálózat lényegesen nagyobb skálafüggetlenséget mutat, mint az egyes országok belső hálózatai. Ugyanakkor a leginkább skálafüggetlen hálózatokat (Németország, Egyesült Királyság, Olaszország, Franciaország) éppen azok az országok adják, amelyek az európai együttműködési hálózat legnagyobb centrumait adják (Párizs, München, London, Milánó, stb.).

6.2.4. A hazai regionális szabadalmi együttműködési hálózat fejlődése

Az előző fejezetpontok elemzése akkor lehet teljes, ha a hazai szabadalmi együttműködési hálózatokat külön, részletesebben is megvizsgáljuk. Magyarországon a NUTS3 régiók megyéket jelentenek, illetve Budapestet, mint önálló régiót, így ebben az esetben a vizsgált hálózat 20 csomópontból áll. A 6.5. ábra mutatja az előző alfejezetben is alkalmazott kis világ mutató illetve a skálafüggetlenségi mutató alakulását 1981 és 2001 között. Az éves volatilitás csökkentése érdekében három éves mozgóátlaggal számolunk, valamint az

¹⁰Fontos persze kiemelni, hogy a kapott eredmények a súlyozott hálózatból számolt skálafüggetlenségi mutatókat takarják. A binarizált kapcsolati mátrix alapján számolt mutatók abszolút értékben kisebbek és alig érzékelhető csökkenést mutatnak a vizsgált időszak alatt, mutatva a periféria integráltságának növekedését.


összehasonlítás miatt az 1981-es értéket 1-nek vettük mindkét mutató esetében, a többi év mutatóinak értékeit pedig ehhez viszonyítottuk.



6.5. ábra. A kis világ és a skálafüggetlenségi mutató alakulása Magyarországon, 1981 és 2001 között (1981 = 1)

Az ábrán az látszik, hogy a kis világ mutató érzékelhetően csökkenő tendenciát mutat a vizsgált időszak alatt, a skálafüggetlenség esetén viszont enyhe, nem túl markáns emelkedés tapasztalható. Ez azt jelenti, hogy a hazai megyéket összekötő szabadalmi kooperációs hálózatok a vizsgált 20 év alatt veszítettek lokális jellegükből, ugyanakkor a centrális megyék szerepe nem csökkent, hanem enyhén növekedett. Így tehát nem mondhatjuk, hogy a hazai hálózati szerkezet a kis világ jelleg csökkenésével a véletlen hálózatokhoz közelítene, annak ellenére sem, hogy a hálózat sűrűsége a vizsgált időszakban növekedett. A skálafüggetlenség markáns fennmaradása hazai szemmel természetesen nem tűnik meglepőnek: vélhetően Budapest játssza a domináns szerepet a hazai szabadalmi tevékenységben és így az együttműködési hálózatban is. A 6.6., 6.7. és 6.8. ábrák a vizsgált hálózat vizuális megjelenítését tartalmazzák, rendre 1981-re, 1990-re és 2000-re. Az ábrákon a vonalak vastagsága jelöli a megyék közötti kapcsolat erősségét (a szabadalmi együttműködések számát).

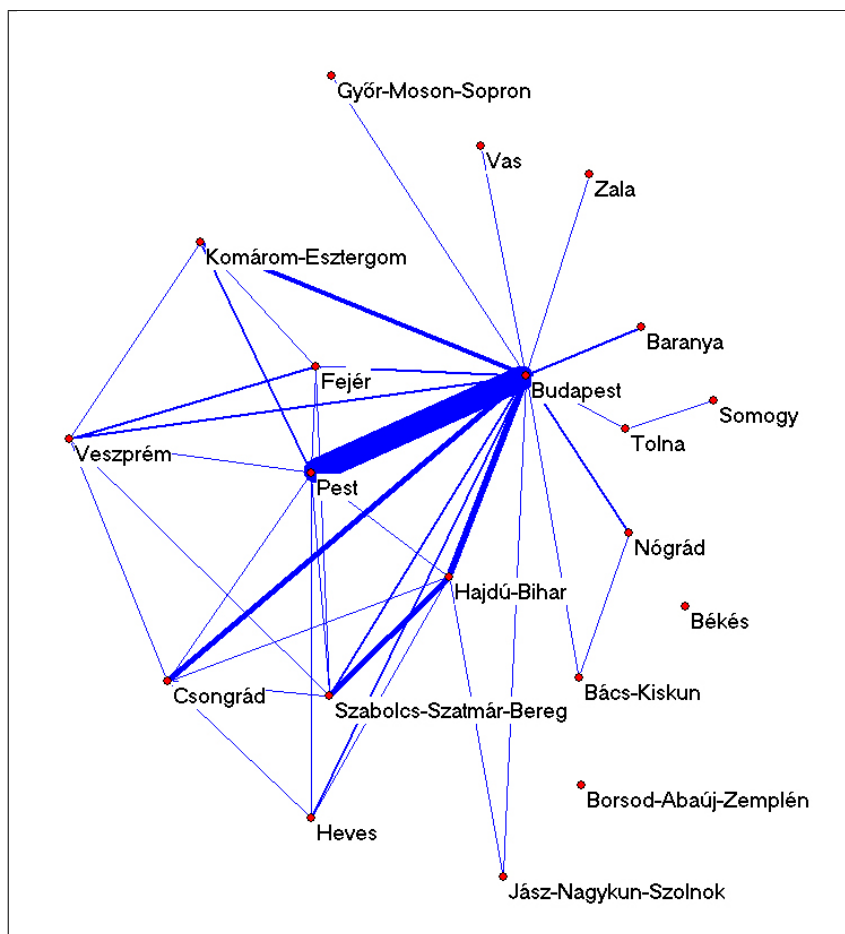
Az 1981-es helyzetet tükrözi a 6.6. ábra. Jól látható, hogy a hálózat erősen skálafüggetlen: két központi csomópontja Budapest és Pest megye és nem található olyan megye, amelyik e két régió valamelyikéhez ne csatlakozna. Az egyedüli kivétel Heves megye, amelyik a vizsgált időszakban nem rendelkezett kapcsolattal. Tanulságos ugyanakkor az is, hogy Heves megyét kivéve valamennyi megye bekapcsolódik a hálózatba. A két centrális csomópont közötti erős kapcsolat dominálja a hálózatot, valamint Csongrád megye szerepe látszik még lényegesnek. A centrumon kívüli régiók esetén Fejér és Hajdú-Bihar megyék rendelkeznek az átlagosnál több kapcsolattal az ábra alapján. Nem jellemző ugyanakkor a periférikus csomópontok közötti kapcsolat, ami a hálózat skálafüggetlenségét erősíti.



6.6. ábra. Hazai NUTS3 régiók közötti szabadalmi együttműködési hálózat 1981-ben

Az 1990-es helyzetet mutató 6.7. ábrán néhány különbség látható az előzőhöz képest. Először is, Budapest centrális szerepe továbbra is domináns, azonban Pest megye központisága valamelyest csökkent, amennyiben azt a hozzá közvetlenül kapcsolódó régiók számával mérjük, ugyanakkor a Budapesttel fennálló kapcsolata lényegesen erősebb lett. A jelentősebb szereplők között továbbra is ott van Csongrád és Hajdú-Bihar megye, ugyanakkor jelentős szerepre tettek szert Komárom-Esztergom és Szabolcs-Szatmár-Bereg megyék miközben Fejér megye szerepe csökkent. Érdekes megemlíteni, hogy Szabolcs-Szatmár-Bereg megye intenzívebben kapcsolódik Hajdú-Bihar megyéhez, mint közvetlenül Budapesthez. Kiesik a hálózatból az 1981-ben még jelentősebb szerepet játszó Borsod-Abaúj-Zemplén megye, marginálisan ugyan, de csatlakozik Heves megye, illetve megjelenik egy olyan csomópont (Somogy megye), amelyik nem csatlakozik közvetlenül egyik centrális régióhoz sem. A periferikus csomópontok közötti kapcsolat továbbra sem jellemző.

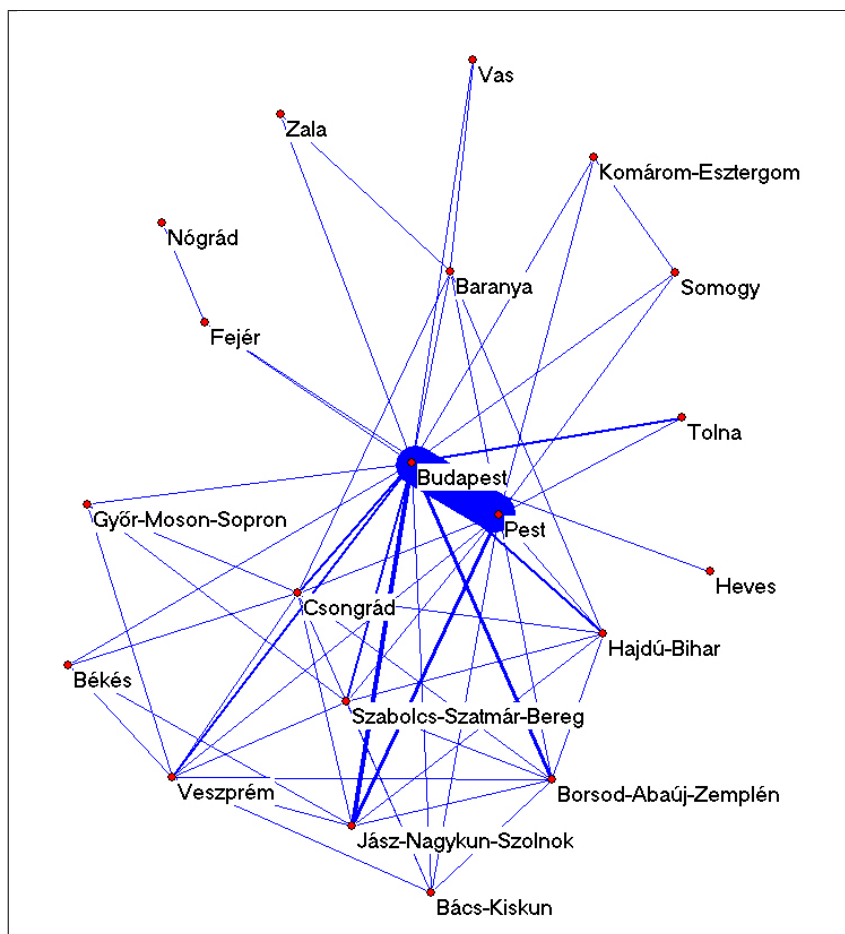
A 6.8. ábra mutatja a 2000-es év szituációját, ahol érzékelhető változások történnek a korábbi két esethez képest. Egyrészt a Budapest és Pest megye közötti kapcsolat erőssége mind abszolút mértékében, mind pedig a hálózat többi kapcsolatának erősségéhez képest is jelentősen emelkedett, továbbra is ez a két régió játssza a centrum szerepét.



6.7. ábra. Hazai NUTS3 régiók közötti szabadalmi együttműködési hálózat 1990-ben

A hálózat többi csomópontja vagy az egyik vagy a másik centrális szereplőhöz közvetlenül csatlakozik, a többség pedig mindkettőhöz. A centrumon kívüli domináns szereplők változnak: Borsod-Abaúj-Zemplén megye ismét a jelentős szereplők közé kerül, akárcsak Jász-Nagykun-Szolnok megye, miközben a többi szereplő jelentősége csökken. Másrészt azonban az is jól látható, hogy a korábbi két pillanatképpel szemben a periferikus csomópontok közötti kapcsolatok szerepe lényegesen növekszik, ami a kapcsolatok erősödő „kuszaságából” látszik. Azt is érdemes megfigyelni, hogy ez a periferikus sűrűség inkább az alföldi és észak-magyarországi régiókra jellemző, miközben a dunántúli régiók közötti együttműködés kisebb.

Természetesen felvethető a kérdés, hogy milyen képet kapnánk, ha Pest megyét és Budapestet egyetlen csomópontként kezelnénk. Ezt persze megtehetjük, azonban addicionális információhoz nem jutunk, mindössze a kapott ábrán jobban nyomon követhető az egyes kapcsolatok súlya, illetve a skálafüggetlen szerkezet még erőteljesebbé válik, hiszen ebben az esetben a periferikus csomópontok egy centrális szereplőhöz kapcsolódnak jelentős intenzitással. Az is látható a 6.8. ábra alapján, hogy tipikusan a két régióból álló centrum-



6.8. ábra. Hazai NUTS3 régiók közötti szabadalmi együttműködési hálózat 2000-ben

hoz kötődő kapcsolatok jelentenek magasabb együttműködési intenzitást, míg a periferikus csomópontok közötti kapcsolatok jellemzően néhány együttműködést takarnak.

6.3. A gazdasági teljesítmény és a hálózati struktúra közötti kapcsolat elemzése

Az előző alfejezetben tárgyalt leíró statisztikák után a gazdasági teljesítmény és a hálózati struktúra közötti kapcsolat empirikus elemzésére teszünk kísérletet. Ebben a szakaszban tulajdonképpen a 4. fejezet főbb következtetéseinek empirikus tesztelésére kerül sor, a 6.1. alfejezetben bemutatott és az előző pontban deskriptív módszerekkel elemzett adatbázis segítségével. Az adatbázist felhasználva egyszerű panel regressziós vizsgálatot végezhetünk. A panel regresszióra azért van szükség, mivel a megfigyelt adatok több időszakon keresztül állnak rendelkezésre. A vizsgálat idődimenziója összesen 22 évet ölel fel, 1981-től 2002-ig, és 27 ország adatait tartalmazza (az Európai Unió 27 tagállamának adatait). Függetlenként először a reál GDP egy főre eső értékét vesszük figyelembe. Azért van szükség az egy főre jutó GDP használatára a teljes GDP-vel szemben, hogy a népességszám és a

	<i>lag0</i>		<i>lag1</i>		<i>lag2</i>	
const	9,750	***	9,755	***	9,761	***
log_CLS	-0,162	***	-0,152	***	-0,146	***
const	9,632	***	9,642	***	9,653	***
log_PATH	-0,200	**	-0,130		-0,113	
const	9,729	***	9,737	***	9,748	***
log_SCALE	0,005		0,005		0,003	
const	9,437	***	9,502	***	9,517	***
log_SCALE_W	0,116	***	0,101	***	0,101	***
	<i>lag3</i>		<i>lag4</i>		<i>lag5</i>	
const	9,811	***	9,843	***	9,843	***
log_CLS	-0,169	***	-0,204	***	-0,204	***
const	9,665	***	9,676	***	9,687	***
log_PATH	-0,107		-0,074		-0,007	
const	9,763	***	9,775	***	9,788	***
log_SCALE	-0,004		-0,004		-0,001	
const	9,555	***	9,563	***	9,580	***
log_SCALE_W	0,090	***	0,095	**	* 0,096	***

6.4. táblázat. Panel-regressziós eredmények a hálózati struktúra és a gazdasági teljesítmény vonatkozásában

GDP közötti pozitív irányú összefüggést kiszűrjük a regresszióból, így a kapott eredmények összevethetőek a 3. fejezet modelljének eredményeivel, ahol a szimulációkat különböző hálózati struktúrák, de mindvégig azonos méretű gazdaságok feltételezésével végeztük el.

A független változók között négy mutatót használunk fel. Először is a klaszterezettség mutatóját ($CLS_{i,t}$), ami az előző alfejezetben elmondottak alapján az i ország t évben kiszámolt klaszterezettségi mutatója, egy azonos méretű, azonos átlagos foksámú véletlen hálózat klaszterezettségi mutatójához viszonyítva. Másodsor hasonló relatív mutatót képzünk az átlagos úthossz tekintetében ($PATH_{i,t}$). A harmadik és negyedik mutató a skálafüggetlenséget mérő mutató az előző fejezethez hasonlóan, egyrészt bináris kapcsolati hálózat alapján ($SCALE_{i,t}$), másrészt pedig súlyozott kapcsolati hálózat alapján ($SCALE_W_{i,t}$) számolva. Mindezek alapján négy panel-regressziós vizsgálatot végzünk el a véletlen koefficiensek módszerét felhasználva, amelyek az alábbi formát öltik:

$$\ln(\text{GDP}_{i,t}) = \beta_0 + \beta_1 \times \ln(\text{NET}_{i,t-\tau}) + v_i + \varepsilon_{i,t} \quad (6.3)$$

ahol a $\text{NET}_{i,t}$ változó helyére a fenti négy hálózati mutató valamelyikét helyettesíthetjük. Az esetleges időbeli hatások feltárása végett a regressziót különböző késleltetésekkel végezzük el, ezt jelzi a τ index a független változó esetében. A késleltetési vizsgálatokat 5 periódusig (évig) végezzük el, így τ értéke 0-tól 5-ig terjed. Az alábbi táblázat mutatja a vizsgált hatszor négy regresszió főbb eredményeit. A részletes eredményeket a fejezethez tartozó függelék F30-F53 táblázatai tartalmazzák.

A kapott eredmények azt mutatják, hogy a késleltetés nélküli esetben a klaszterezettség valamint az átlagos elérési úthossz negatív, szignifikáns kapcsolatban áll a kibocsátással. Egészen pontosan ez a következőt jelenti. A klaszterezettség együttható esetében a ma-

gasabb klaszterezettség egyértelműen alacsonyabb kibocsátási szinttel társul, az alacsony klaszterezettség pedig magas kibocsátással. Ez a tendencia pontosan megfelel annak, amit a 3. fejezet modelljében a Watts-Strogatz modell kapcsán kimutattunk: ott is azt láttuk, hogy a magasabb klaszterezettségű, vagyis erős lokális kapcsolatokkal rendelkező gazdasági hálózatok esetén alacsonyabb kibocsátási szintet kapunk, míg a véletlenszerűbb, vagyis alacsonyabb klaszterezettségi szintű hálózatok esetén a gazdaság kibocsátása magasabb. Úgy látszik, hogy a rendelkezésünkre álló adatok a tudáshálózatok regionális dimenziója tekintetében konzisztensek a modellünk által adott eredményekkel. A szignifikáns, negatív irányú kapcsolat fennmarad a késleltetési modellek esetén is, sőt, azt látjuk, hogy a klaszterezettségi együttható koefficiense a 4 és 5 éves késleltetés esetén a legmagasabb, bár a különbség nem tekinthető különösebben jelentősnek. További késleltetések vizsgálata során kiderül, hogy a klaszterezettség együtthatója 4-7 éves késleltetéseknél éri el a legmagasabb abszolút értéket.

Az átlagos elérési út esetén szintén negatív összefüggést találunk: azokban az esetekben, amikor az átlagos elérési út hosszabb, tipikusan alacsony kibocsátást figyelhetünk meg, illetve fordítva, a rövidebb elérési utak magasabb kibocsátással járnak együtt. Ez az eredmény szintén egybevág a Watts-Strogatz modellen alapuló szimulációink tapasztalatával: a rövid elérési úthossz tipikusan a véletlen hálózatokra jellemző, és ezekben az esetekben figyelhetünk meg a magasabb kibocsátási szinteket, míg a hosszú elérési úttal jellemezhető szabályos hálózatokra jellemző kibocsátási szint alacsonyabb. A vizsgálat során csak a késleltetés nélküli modellnél kapunk szignifikáns eredményt, a negatív előjel azonban mindvégig megmarad, bár az együttható abszolút értéke egyre kisebb. További vizsgálatok során kiderül, hogy 7-9 éves késleltetés esetén az átlagos elérési út pozitív szignifikáns kapcsolatban áll a kibocsátással.

Ez az utóbbi eredmény érdekes következtetésekre vezet. Egy adott időszakban akkor figyelhetünk meg magasabb kibocsátást egy ország esetén, amennyiben a hálózati struktúra jóval korábbi időszakokban hosszabb elérési utakkal jellemezhető, a jelenben pedig rövidebb elérési utakkal. Ez a jelenség arra utalhat, hogy a tudás felhalmozásának és terjedésének szakaszai elválnak egymástól abban az értelemben, hogy különböző hálózati struktúrák kedvezőek az egyes fázisokban. A tudás kezdeti felhalmozásához a lokálisan sűrű, relatíve hosszú elérési utakkal jellemezhető hálózat kedvező, majd később, a tudás terjedése szempontjából a rövid elérési utak válnak fontossá. A kibocsátásban ez olyan módon jelenik meg, hogy a korai, lokálisan sűrű struktúrák katalizálják az új tudás létrehozását, amely aztán a magasabb kibocsátási szintek tudásbázisául szolgál a későbbiekben. A már létrejött tudásbázis azonban úgy tudja kifejteni kedvező hatását, ha a hálózati struktúra áthidaló kapcsolatok kialakításával a tudás-diffúziót felgyorsítja.

A skálafüggetlenség vizsgálata során kapott eredmények szintén egybevágóak a 3. fejezet szimulációinak eredményével, ugyanakkor egyértelműen látszik a súlyozott és a bináris hálózat alapján számolt mutatók közötti különbség is. A 4. fejezet szimulációi során azt az eredményt kaptuk, hogy minél centralizáltabb egy hálózat, azaz minél inkább jellemző rá a

skálafüggetlenség, a hálózatra épülő gazdaság kibocsátása annál magasabb, ellenpontként egy véletlenszerűbb hálózatot tekintve. A 6.1. táblázat adataiból egyértelműen látszik, hogy a skálafüggetlenség pozitív szignifikáns kapcsolatban áll a kibocsátással, amennyiben a skálafüggetlenségi mutató kiszámítása során a súlyozott hálózatot vesszük figyelembe, azaz nem redukáljuk a régiók közötti kapcsolatokat egységnyi értékre, függetlenül a tényleges kapcsolati intenzitástól. Egészen pontosan azt találjuk, hogy a magasabb kibocsátás együtt jár a skálafüggetlenségi mutatónk magasabb értékeivel, ez utóbbi pedig a hálózat fokszám-eloszlását leíró hatványfüggvény kitevőjének felel meg.

Fontos kiemelnünk, hogy a pozitív irányú kapcsolat azért jelenti a 3. fejezet modelljében talált pozitív kapcsolat alátámasztását, mert az empirikus vizsgálatban általunk használt $SCALE_{i,t}$ és $SCALE_W_{i,t}$ mutatók relatív mutatók, amelyekben a ténylegesen megfigyelt kitevőket egy hipotetikus, szélsőségesen skálafüggetlen hálózatban adódó kitevőhöz viszonyítjuk. Minthogy mind a megfigyelt hálózatok ilyen értékei, mind pedig a hipotetikus hálózatok kitevői negatívak (a skálafüggetlenség okán), így eredményül egy pozitív számot kapunk. Minél nagyobb ez a pozitív szám, annál nagyobb a megfigyelt hálózat kitevője a hipotetikus hálózat kitevőjéhez képest, következésképpen annál inkább skálafüggetlen a megfigyelt hálózat. Így tehát a $SCALE_{i,t}$ és $SCALE_W_{i,t}$ mutatók növekedése a skálafüggetlenség növekedését mutatja, következésképpen az általunk feltárt pozitív kapcsolat a $SCALE_W_{i,t}$ mutató és a kibocsátás között azt jelzi, hogy tipikusan a skálafüggetlenebb hálózatok jellemezhetőek magasabb kibocsátással. Empirikus eredményeink tehát a Watts-Strogatz modell mellett a módosított Barabási-Albert modellen alapuló szimulációk tapasztalatait is megerősítik.

Ez az eredmény látszólag ellentmondásban áll a klaszterezettségre és az átlagos elérési úthosszra kapott eredményekkel: ott ugyanis azt láttuk, hogy a véletlenszerű hálózati struktúra felé történő elmozdulás kapcsolódik össze a magasabb kibocsátással, most viszont éppen azt látjuk, hogy a skálafüggetlenség növekedése, azaz a struktúra speciális szabályok szerinti szerveződése is pozitív hatással van a kibocsátásra. Fontos kiemelni, hogy ez az ellentmondás csak látszólagos, ugyanis a skálafüggetlen hálózatok tipikusan rövid elérési utakkal jellemezhetőek, így az átlagos elérési úthossz kapcsán adódó eredmény egybevág a skálafüggetlenségre kapott összefüggésekkel. A klaszterezettségi mutató értéke ugyanakkor nincsen szoros kapcsolatban a skálafüggetlenséggel: skálafüggetlen hálózatok lehetnek erősebben és gyengébben klaszterezettek, bár az igaz, hogy minél szélsőségesebben skálafüggetlen egy hálózat, a klaszterezettség egyre csökken. Így a kapott eredmények arra mutatnak, hogy azok a hálózati struktúrák adják a legkedvezőbb alapot a magasabb gazdasági teljesítményhez, amelyek egyszerre jellemezhetőek magas centralitással és alacsony szintű klaszterezettséggel.

Hasonló elemzéseket végezhetők úgy is, hogy magyarázott változóként nem a GDP szintjét, hanem a GDP éves növekedési ütemét szerepeltetjük a (6.3) egyenletben. Ezekre a regressziókra nem adódnak szignifikáns koefficiensek, leszámítva az 5 éves késleltetést, ahol a klaszterezettség esetében enyhén szignifikáns negatív, az átlagos elérési úthossz esetében

pedig enyhén szignifikáns pozitív együtttható adódik. A regressziós eredmények közlésétől, tekintve azok marginális relevanciáját, eltekintünk.

Mindezek alapján azt állapíthatjuk meg, hogy a hálózati struktúra és a gazdasági teljesítmény között létezik szignifikáns kapcsolat. Érdekes ugyanakkor kitérnünk a bevezetőben és a hálózati mutatók kapcsán már tárgyalt két hálózati modellel kapcsolatos érvelések és a most prezentált empirikus eredmények közötti kapcsolatokra. Elsősorban a kis világ struktúrával kapcsolatos gondolatokat emelnénk ki. Több tanulmány is kiemeli (Cowan, 2005; Cowan és szerzőtársai, 2006), hogy a kis világok hatékony hálózati struktúrának tekinthetők, mivel egyszerre biztosítják a lokális kohéziót (a magas klaszterezettség révén) és a gyors diffúziót (a rövid elérési utak okán). Az általunk kapott eredmények ugyanakkor részben ellentmondanak ennek a képnek: azt látjuk, hogy azok a hálózati struktúrák kapcsolódnak a magasabb kibocsátási szinthez, amelyek kevésbé a lokális struktúrákra, mint inkább a gyors elérési utakra épülnek.

Természetesen az eredmények nem engednek teljes rálátást a hálózati struktúra és a hálózati struktúrára épülő rendszer teljesítménye közötti összefüggésekre, csupán a struktúrát leíró néhány mutató és a teljesítmény együttmozgását figyelhetjük meg. A klaszterezettségi mutató és az átlagos elérési út esetén feltárt negatív kapcsolat takarhat egy olyan folyamatot is, amely a szabályos, vagyis magas klaszterezettségű és hosszú elérési utakkal jellemezhető hálózati struktúra irányából a kis világok felé történő elmozdulást jelent. Ez az elmozdulás ugyanis mind a klaszterezettség, mind pedig az átlagos elérési úthossz csökkenésével jár. A kis világok jelentősége éppen abban áll, hogy a két mutató csökkenésének üteme eltérő, így található olyan tartomány, ahol a hálózat lokális struktúrái fennmaradnak, az átlagos elérési úthossz azonban már jelentősen lerövidül. Így az általunk kapott eredmények tükrözhetik ezt a folyamatot is, amely során egy lokálisan erősen strukturált hálózat felől a kis világokra jellemző struktúrák irányába mozdul el a hálózati struktúra.

A bevezetőből kitűnt, hogy a valóságban megfigyelhető hálózatok jelentős része skálafüggetlen tulajdonságokkal rendelkezik. Barabási (2002) úgy érvel, hogy ez a speciális struktúra a komplex rendszerek egyik fontos szerveződési elve lehet. Ez felveti azt a gondolatot, hogy egyfajta evolúciós fejlődés során a komplex rendszerek struktúrája a skálafüggetlen struktúra felé mozdul, mivel ez a struktúra nagyfokú hatékonyságot biztosít a rendszer aggregált teljesítménye szempontjából. Az empirikus eredmények érdekes adalékkal szolgálnak ebben a tekintetben: azt látjuk, hogy a skálafüggetlen hálózati struktúrák valóban magasabb kibocsátással társulnak, így egy első megerősítést nyerhetünk arra a hipotézisre vonatkozóan, hogy a valóságban megfigyelt hálózati struktúrák azért mutatják a skálafüggetlenség jellemzőit, mivel ez a struktúra a rendszer egészének teljesítménye szempontjából kiemelkedően hatékony.

7. fejezet

Fejlesztéspolitikai szimulációk kalibrált modell segítségével

Az előző fejezetekben egyfelől bemutattam egy olyan elméleti modellt, amely a hálózati struktúrák és a gazdasági tevékenység kölcsönhatásának kérdésével foglalkozik. Ezt követően a modell alapvetéseinek és eredményeinek empirikus vizsgálatát végeztem el, amely vizsgálat megerősített abban, hogy a modell feltevései helyesek és egyszerűsége ellenére alkalmas kiindulópontja lehet egy olyan, átfogóbb modell kialakításának, amely a tudáshálózatok explicit modellezésén keresztül vihet közelebb a technológiai fejlődés és a gazdasági növekedés regionális kérdéseinek megértéséhez.

A továbbiakban a 3. fejezetben bemutatott modellt az 5. fejezet empirikus tapasztalatainak segítségével kalibrálom és az így kalibrált modell segítségével olyan szimulációkat végzek el, amelyek a technológiai fejlődés térbeli kérdéseire adhatnak adekvát válaszokat a fejlesztéspolitika szemszögéből. Az alkalmazott módszer tulajdonképpen az 5. fejezet empirikus elemzését kapcsolja össze a 4.5. alfejezet szimulációival amennyiben a szimulációkat empirikus alapokon becsült-kalibrált modell segítségével végezzük el.

7.1. A modell kalibrálása

A modell kalibrálásának a célja az, hogy a 3. fejezetben bemutatott általános egyensúlyi algoritmust lefuttatva a vizsgált gazdaságra jellemző, empirikusan megfigyelt értékeket kapjuk vissza. Jelen esetben az a cél, hogy olyan paraméter értékeket határozzunk meg, amelyek mellett a modell eredményeül kapott kibocsátási vektor megegyezik az empirikus adatokkal. Emlékeztetőül közöljük a modell paramétereit és endogén változóit.

A paraméterek a következők:

- N – a gazdasági aktorok (vállalatok, vagy régiók) száma.
- α – a termelési függvény rugalmassági paramétere.

- σ – a végső felhasználású termékek közötti helyettesítés paramétere.
- θ – a spilloverek intenzitását mérő paraméter.
- ρ – a tudás-területek közötti helyettesítés paramétere.
- \mathbf{k} – a belső tudásállományok N elemű vektora.
- I – a nominális jövedelem vagy pénzmennyiség.
- \bar{L} – a rendelkezésre álló munkamennyiség (munkakínálat).
- \mathbf{A} – a hálózati kapcsolatok mátrixa.

Az endogén változók a következők:

- w – a nominálbér szintje a gazdaság egészében.
- \mathbf{y} – a kibocsátási szintek N elemű vektora.
- \mathbf{p} – az árszintek N elemű vektora.

A modell kalibrálását az 5. fejezet empirikus tapasztalatainak segítségével végezzük el. Ez egyben azt is jelenti, hogy az ott felhasznált adatbázis segítségével végezzük el a kalibrálást. Ez egyrészt meghatározza az N paraméter értékét: a vizsgáltunkban összesen 96 régió szerepelt, így $N = 96$ adódik.

7.1.1. Átvett és becsült paraméterek

Az előző bekezdésben felsorolt paraméterek közül néhánynak az értékére vonatkozóan az 5. fejezet empirikus vizsgálatai adnak támpontot.

Elsőként a termelési függvény elaszticitási paraméterének (α), értékét határozzuk meg. A 4. fejezet szimulációi során a makroökonómiai modellekben szokásos értékkel számoltunk esetén. Az 5. fejezet empirikus vizsgálatai azonban lehetőséget adnak arra, hogy ettől alkalmasabb értéket válasszunk. Ez elsősorban azért is lényeges, mivel a modellünket most a high-tech szektorra kalibráljuk. Az 5. fejezet 5.3. és 5.4. táblázatai tartalmazzák a high-tech szektor termelési függvényére vonatkozó regressziók eredményét. A regionális GDP becslése során alkalmazott különböző korrekciós tényezőktől függően a munkafelhasználás elaszticitására 0,91-os és 1,00-os értékeket kapunk.

A nominális jövedelem a vizsgált három országra az Eurostat adatai alapján könnyen meghatározható. A rendelkezésre álló munkamennyiség az Eurostat foglalkoztatási adatai alapján szintén könnyen meghatározható. További fontos paramétere a modellnek az kapcsolati mátrix. Az 5. fejezetben használt adatbázisból levezetett kapcsolati mátrix szintén adottnak tetelezhető. A ρ paraméter értékét a linearitás és az empirikus vizsgálatok esetén használt

függvényformának megfelelően egységnyiinek vesszük. A σ paraméter értékét a 4. fejezetben hivatkozott makroökonómiai modellek alapján 0,85-nek állítjuk be. A θ paraméter értékét a következő fejezetpontban határozzuk meg.

7.1.2. A spillover paraméter kalibrálása

A spillover paraméter meghatározása alapvetően két módon történhet. Az egyik módszer, ha az 5. fejezet empirikus vizsgálatait vesszük alapul: az ott elvégzett regressziós elemzések tulajdonképpen a θ paraméterre adtak becsléseket. Láttuk ugyanakkor, hogy ezek a becslések nem biztosítanak meggyőző eredményeket, legalábbis nem abban a formában, ahogyan az a modell kalibrálása során felhasználható lenne. Az 5.2.2.5. alfejezetben viszont azt láttuk, hogy a kapott negatív koefficiensek konzisztensek lehetnek a modell tudáshálózatának specifikus struktúrájával. Így a becsült paraméterek alkalmazása mellett egy további módszer is adódik: az empirikus vizsgálatok együttthatóiból visszakövetkeztethetünk egy olyan θ értékre, amelyek mellett (és az empirikus hálózati struktúrát figyelembe véve) a tapasztalt együttthatókat kapjuk eredményül. E módszer részletes leírását adom meg az alábbiakban.

Első lépésként meg kell határozni azt az empirikus r értéket, amelyek a módosított Barabási-Albert modellben a hálózat struktúrájának skálafüggetlenségét méri. E paraméter meghatározására egy meglehetősen egyszerű módszer adódik. A 6. fejezet vizsgálataiban a skálafüggetlenség mértékét egy relatív mutatószám alkalmazásával határoztuk meg: az empirikus foksám-eloszlás hatványfüggvényének kitevőjét egy olyan kitevőhöz viszonyítottuk, amely egy azonos méretű, azonos átlagos foksámú, de szélsőségesen skálafüggetlen hálózat esetében adódna. Egy ilyen relatív mutató lényegében reprodukálja a módosított Barabási-Albert modell r paraméterét: értéke egyhez közeli a szélsőségesen skálafüggetlen hálózatok esetén és nullához tart a véletlen hálózatok esetén.

A 7.1. táblázat tartalmazza a hatványfüggvény kitevőjének a hálózatban megfigyelt értékeit, valamint a megfelelő elemszámú és átlagos foksámú, szélsőségesen skálafüggetlen hálózat hasonló mutatóját, ezen felül a két érték hányadosait, amely értékek alapul szolgálnak az r paraméter meghatározásához.

	2000	2001	2002	Átlag
<i>Empirikus értékek</i>	-0,565	-0,450	-0,377	-0,464
<i>Szimulált értékek</i>	-0,682	-0,656	-0,620	-0,653
<i>r</i>	0,828	0,686	0,609	0,708


7.1. táblázat. Skálafüggetlenség empirikus és szimulált értékei

A táblázatban közölt adatokat a súlyozatlan kapcsolati mátrixok alapján határoztuk meg mind az empirikus, mind pedig a szimulált hálózatok esetén, ezért kaptuk az abszolút értékben relatíve kisebb eredményeket. Választásunk egyik oka, hogy a súlyozott hálózat használatánál az átlagos foksám meghaladja a csomópontok számát, ami viszont a módosított Barabási-Albert modell alkalmazása során problémát jelent. A másik ok, hogy a

kalibrált modell segítségével végzett szimulációk során is bináris kapcsolati mátrixot alkalmazunk, és így konzisztensebb eredményekhez jutunk, ha itt is a bináris kapcsolati mátrixot használjuk fel.

A táblázat alapján látható, hogy az empirikus értékek viszonylag nagy szóródást mutatnak a három év alatt, ugyanakkor az r hányados mindhárom évben a relatíve magas tartományban található. A továbbiakban az átlagként adódó 0,7-es értéket használjuk fel.

Miután az r paraméter értékét meghatároztuk, egyszerűen elvégezzük azt a szimulációt, amelyet az 5. fejezetben használtunk a TFP és a külső tudás közötti viszony meghatározásához, a különbség csupán annyi, hogy most rögzített ρ és r értékek mellett dolgozunk. Így az egyedüli változónk a θ paraméter marad. θ különböző értékeire lefuttatjuk a szimulációt, így a paraméter valamennyi értékénél kiszámíthatjuk, hogy a TFP és a külső tudás együtt-hatója mekkora. Ezek után a θ értékek közül kiválasztjuk azt, amely mellett a szimuláció az empirikusan megfigyelt regressziós együtthatóhoz legközelebbi értéket adja. A szimuláció iterálásával θ értéke tetszőleges pontossággal meghatározható.



7.1. ábra. A TFP és a külső tudás közötti kapcsolat regressziós együtthatója θ függvényében

Az eljárás tehát a következő. Először is a régiós belső tudás-értékeket vesszük alapul, így a modellünk \mathbf{k} vektora adott.¹ A ρ paraméter értékét egységnyinek választjuk a korábbi megfontolásoknak megfelelően. Ezt követően a módosított Barabási-Albert modell alapján létrehozunk egy skálafüggetlen hálózatot (kapcsolati mátrixot), ahol a csomópontok száma megfelel a vizsgálatban szereplő régiók számának ($N = 96$), az átlagos fokszám az empirikus értékeknek megfelelően 15, a módosított Barabási-Albert modell r paramétere pedig a 7.1. táblázatnak megfelelően 0,7-es értéket kap. Az így létrehozott hálózat \mathbf{A} kapcsolati


¹Ezeket az értékeket a high-tech szektorhoz kapcsolódó szabadalomszámok szolgáltatják, ahogyan azt az 5. fejezetben bevezettük. A rendelkezésünkre álló három év adatait átlagolva kaptuk meg a most felhasznált \mathbf{k} vektort.

mátrixa alapján ($\rho = 1$ és θ tetszőleges értéke mellett) a (3.5) képlet segítségével kiszámíthatjuk a régiók TFP értékeit. Miután ezek az értékek adottak, egyszerű regressziót számítunk a TFP értékek és a külső tudás, vagyis az \mathbf{Ak} szorzat között. Ezzel a módszerrel θ különböző értékei mellett kiszámíthatjuk az utóbbi regresszióban a külső tudás együtthatóját és megkeressük azt a θ értéket, amelyre a szimulált koefficiensek megegyeznek a tapasztalati értékekkel.

A 7.1. ábrán a TFP és a külső tudás között felállított regressziós egyenlet fenti eljárás szerint megbecsült β együtthatóit láthatjuk, θ függvényében. Az ábrán jelöltük az adatpontokra illeszthető egyenest is, melynek egyenlete:

$$\beta = -0,2786 + 5,5341 \times \theta \quad (7.1)$$

Látható, hogy a spillover paraméter egyre magasabb értékei növelik a β regressziós koefficiens értékét. Az alkalmazott paramétertartományban a koefficiens negatív értéket csak θ alacsony értékei mellett, egy szűk tartományban vesz fel. Ha a kinagyítjuk a $0 \leq \theta \leq 0,1$ tartományt, akkor a 7.2. ábrát kapjuk.



7.2. ábra. A TFP és a külső tudás közötti kapcsolat regressziós együtthatója θ függvényében, $0 \leq \theta \leq 0,1$

A (7.1) egyenlet segítségével most már könnyen kiszámíthatjuk azt a θ értéket, amelyre a szimulációk során kapott β koefficiens megegyezik az empirikus értékekkel. Minthogy az empirikus értékek $-0,063$ és $-0,084$ között találhatóak (lásd az 5.7. táblázatot), az átlagos $-0,074$ -es értékre kalibráljuk a spillover paraméter értékét. Ezt a (7.1) egyenletben β helyére helyettesítve kapjuk, hogy $\theta = 0,0371$.

Az így kapott spillover paraméter ugyan meglehetősen alacsony, de fontos kiemelnünk, hogy az 5. fejezetben sem kaptunk lényegesen nagyobb értéket akkor, amikor az 5.2.2.4. feje-

zetpontban a korrigált mutatószámok alapján pozitív kapcsolatot mutattunk ki a TFP és a külső tudás között.²

Természetesen az eredményeinket a többi paraméter megválasztott értéke is befolyásolja, így elsősorban a hálózat skálafüggetlenségét leíró r paraméter megválasztása. Láttuk, hogy ez a paraméter 0,8 és 0,6 körül is alakulhat. Amennyiben az átlagos 0,7-es érték helyett a 0,8-as értékkel számolunk, a fenti eljárást követve θ értékére 0,11-et kapunk. Annak érdekében, hogy a fenti bizonytalanságokat is figyelembe vegyük, a fejezet szimulációiban θ értékét 0,05-nek állítjuk be.

7.1.3. A kalibrálás tapasztalati bázisa

A kalibrálás legfőbb bázisa a regionális GDP-k vektora. Ezeket az értékeket az 5. fejezetben használt adatok alapján határozzuk meg. Az átfogóbb kép érdekében a kalibrációt nem egyetlen évre végezzük el, hanem a rendelkezésünkre álló 3 év (2000, 2001, 2002) GDP értékeinek átlagát vesszük alapul a kalibrálás során. Ezzel a rövid távú tendenciákból (üzleti ciklusokból) fakadó volatilitást legalábbis részben kiszűrhetjük és egy relatíve hosszabb távú tendenciára építhetjük a kalibrálást.

7.1.4. A kalibrálás menete

A kalibrálást kétlépcsős folyamatban végezzük el, ahogyan a 3. fejezet modelljében is a modell megoldása két részre oszlott. Ott az \mathbf{A} kapcsolati mátrix és a \mathbf{k} tudásvektor segítségével meghatároztuk a K_i TFP szinteket, majd e TFP értékek segítségével tudtuk a modell általános egyensúlyi helyzetét meghatározni. A kalibrálási folyamat tulajdonképpen ennek a megoldási folyamatnak a fordítottja.

Első lépésben a 3. fejezet (3.8) összefüggését használjuk fel. Ez az összefüggés az i -edik termék keresletét írja fel az árak függvényében. Minthogy egyensúlyban a kereslet és a kínálat valamennyi piacon megegyezik, az összefüggés tekinthető úgy is, mint ami az árszintek és a kibocsátási szintek közötti kölcsönös összefüggést jeleníti meg:³

$$y_i = p_i^{-\varepsilon} \frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}}, i = 1, \dots, N \quad (7.2)$$

ahol $\varepsilon = 1/(1 - \sigma)$, akárcsak a 3. fejezet jelölésrendszerében. Helyettesítsük az ismert \hat{y}_i empirikus GDP értékeket az egyenlet bal oldalára:

$$\hat{y}_i = p_i^{-\varepsilon} \frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}}, i = 1, \dots, N \quad (7.3)$$

²Emlékeztetőül: ott 0,1 körüli értékeket találtunk.

³A változók jelölése jelen esetben nem a 3.3. alfejezet konvencióit követi: a változók fölötti kalap ott a reprezentatív vállalat változóit jelölte, most azonban az empirikus vagy kalibrált értékeket.

Ismert I és σ értékek esetén (illetve természetesen adott N mellett) a (7.3) egyenlet egyszerű numerikus módszerekkel megoldható p_i -re, így megkapjuk az árszínvonalak azon $\hat{\mathbf{p}}$ vektorát, amelyek konzisztensek a megfigyelt $\hat{\mathbf{y}}$ GDP értékekkel valamint a paraméterek adott értékeivel.

Ezt követően a 3. fejezet modelljének (3.12) egyenletét használjuk fel. Ez az egyenlet az egyensúlyi árvektort adja meg:

$$p_i = w^\varphi K_i^{-\frac{\varphi}{\alpha}} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^\varphi \left(\frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} \right)^{\frac{1-\alpha}{\alpha}\varphi}, \quad i = 1, \dots, N \quad (7.4)$$

ahol $\varphi = \alpha/(\varepsilon(1 - \alpha) + \alpha)$. A (7.4) összefüggés egyszerűen átrendezhető K_i -re, majd az árszínvonalak helyére a $\hat{\mathbf{p}}$ vektor elemeit helyettesítve megkapjuk a kalibrált TFP értékeket:

$$\hat{K}_i = w^\alpha \left(\frac{1}{\alpha\sigma} \right)^\alpha I^{1-\alpha} \hat{p}_i^{-\left(\frac{1-\alpha}{1-\sigma} + \alpha\right)} \left(\sum_{j=1}^N \hat{p}_j^{-1/\sigma} \right)^{\alpha-1}, \quad i = 1, \dots, N \quad (7.5)$$

Így megkapjuk a TFP értékek azon $\hat{\mathbf{K}}$ vektorát, amelyek konzisztensek az adott paraméterekkel és a regionális GDP értékekkel. A kalibrált modell azonban tartalmaz egy további szabadsági fokot. Ha egyelőre eltekintünk a modell TFP-blokkjától (vagyis a K_i értékeket meghatározó tudás-aggregátortól), akkor azt látjuk, hogy a $\hat{\mathbf{K}}$ vektor kiszámításához az α , a σ , az I és az N paramétereket használtuk fel, továbbá az egyensúlyi bérszintet, w -t. A modell megoldásához azonban szükségünk volt az \bar{L} paraméter értékére is. Ugyanakkor a tapasztalati GDP értékekből visszszámolt $\hat{\mathbf{K}}$ vektor és a tapasztalati \bar{L} paraméter segítségével meghatározott általános egyensúlyi helyzet nem szükségszerűen egyezik meg a GDP empirikus értékeivel. Ebben a szituációban természetesen kézenfekvő az \bar{L} paraméter értékét alkalmasan megválasztani úgy, hogy a kiszámolt és az empirikus GDP értékek megegyezzenek, így lekötve a „maradék” szabadsági fokot. A szabadsági fok megkötése azonban nem csak az \bar{L} paraméteren keresztül történhet, hanem a régiók száma miatt rögzített N paraméter kivételével valamennyi, eddig előforduló paraméter (α , σ , I), vagy akár a bérszint (w) alkalmas megválasztásával is.

A rendelkezésre álló öt lehetőség közül a munkabért választjuk a kalibrálás során. A választásnak praktikus okai vannak, mégpedig, hogy α és σ értékre vonatkozóan rendelkezésünkre állnak megbízható értékek, az I és \bar{L} paraméterek pedig az Eurostat adatai alapján meghatározhatóak. A bérszintekre azonban nincsen elérhető adat az általunk használt Eurostat forrásokból,⁴ így célszerű ezt az értéket meghagyni olyan változónak, amely alkalmas (és ezért szükségszerűen a valós adatokkal nem konzisztens) megválasztása a modell kalibrálását lehetővé teszi a régiós GDP értékekre.

A kalibrálás második lépéseként a tapasztalati adatokkal konzisztensen kiszámított $\hat{\mathbf{K}}$ vektorból számítjuk vissza a régiók saját tudásmennyiségét, azaz a \mathbf{k} vektor értékeit. Figye-

⁴Az általunk használt szektorális szűkítés ebben a tekintetben további nehézségeket jelentene.

lembe véve a $\rho = 1$ egyszerűsítést, ez a lépés meglehetősen egyszerű. Felírva a 3. fejezet (3.5) összefüggését a $\rho = 1$ helyettesítéssel, az alábbi alakot kapjuk:

$$K_i = k_i + \theta \sum_{j=1}^N a_{ij} k_j, i = 1, \dots, N \quad (7.6)$$

vagy mátrix-jelöléseket alkalmazva:

$$\mathbf{K} = \mathbf{k} + \theta \mathbf{A} \mathbf{k} \quad (7.7)$$

A (7.7) összefüggés alkalmasabb formába is írható, figyelembe véve a jobb oldali kifejezésben fellelhető szabályosságot:

$$\mathbf{K} = \mathbf{B} \mathbf{k} \quad (7.8)$$

ahol a \mathbf{B} mátrix valamennyi diagonális eleme $1 + \theta a_{ii}$, a többi elem pedig θa_{ij} :

$$\mathbf{B} = \begin{bmatrix} 1 + \theta a_{11} & \theta a_{12} & \cdots & \theta a_{1N} \\ \theta a_{21} & 1 + \theta a_{22} & \cdots & \theta a_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \theta a_{N1} & \theta a_{N2} & \cdots & 1 + \theta a_{NN} \end{bmatrix} \quad (7.9)$$

Ezt követően a (7.9) egyenlet mindkét oldalát balról megszorozva a \mathbf{B} mátrix inverzével, egyszerű összefüggést kapunk a régiók saját tudásának vektorára:

$$\mathbf{k} = \mathbf{B}^{-1} \hat{\mathbf{K}} \quad (7.10)$$

Így tehát rendelkezésünkre áll a kalibrált $\hat{\mathbf{k}}$ vektor, és a regionális kapcsolatok empirikus alapokon létrehozott \mathbf{A} mátrixa (amely jelen esetben egy bináris mátrix). E két adathalmaz, valamint a szintén kalibrált θ paraméter és az egységnyinek tekintett ρ paraméter segítségével a 3. fejezet (3.5) összefüggése alapján megkapjuk a TFP értékek $\hat{\mathbf{K}}$ kalibrált vektorát.

A $\hat{\mathbf{k}}$ TFP értékek, az I , \bar{L} empirikusan adott paraméterek, a becsült α paraméter, és a más modellekből áthozott σ paraméter alapján ezt követően meghatározható az általános egyensúlyi helyzet és ezzel együtt a regionális kibocsátások $\hat{\mathbf{y}}$ vektora, amely a pontos kalibrálás alapján megegyezik a megfigyelt GDP értékekkel. A kalibrálás során nyert adatok táblázata megtalálható a fejezethez tartozó függelékben. A továbbiakban a rendelkezésünkre álló kalibrált modell segítségével végzünk olyan szimulációkat, amelyek a regionális fejlesztéspolitika szempontjából szolgálhatnak fontos tanulságokkal. A bemutatásra kerülő szimulációk hangsúlyozottan szemléltető jellegűek: a cél inkább a modellben rejlő lehetőségek felvetése.

7.2. Szimulációk a kalibrált modell segítségével

Az előző fejezetpont alapján kalibrált modell segítségével lehetőségünk nyílik arra, hogy a technológiai diffúzió dinamikáját vizsgáljuk regionális szempontból. Ehhez a 4. fejezetben már alkalmazott szimulációs technikát használjuk fel, most a kalibrált modell alapján.

A 4.5.2. pontban olyan szimulációkat vizsgáltunk, ahol a modellgazdaságot technológiai sokkok érték különböző feltételrendszerek mellett: a hálózati struktúrában rejlő különbségek miképpen hatnak a technológiai diffúzió jellemzőire és a technológiai sokkhatások által generált aggregált gazdasági növekedésre. A kalibrált modell esetén a hálózati struktúra különbségei természetesen nem értelmezhetőek, hiszen rögzített (empirikusan adott) struktúrával dolgozunk. Ugyanakkor a 4. fejezet másik fő kérdése, nevezetesen a technológiai sokkhatás helyszínének hatása a diffúzió folyamatára és az aggregált outputra már vizsgálható a kalibrált modellben is.⁵

A technológiai sokkhatások lokalizációja a jelen kontextusban úgy értelmezhető, hogy a TFP szinteket érő technológiai sokkhatások a hálózat csomópontjaiként adott régiók valamelyikét érintik. A hálózati struktúra és az általános egyensúlyi helyzet változásai eztán eltérő dinamikát adnak különböző belépési pontok esetén. A 4. fejezetben láttuk, hogy a technológiai sokkhatás lokalizációjának kérdése a Barabási-Albert modellben jelenik meg élesen, egészen pontosan abban az esetben, amikor a hálózat struktúrájára a skálafüggetlenség jellemző. Ebben a szituációban ugyanis fontos, hogy a technológiai sokk egy centrális szereplőt vagy egy periférikus szereplőt érint.


7.2.1. Centrum és periféria a gazdaságban és a hálózatokban

A centrális pozíció természetesen többféle dimenzió mentén is értelmezhető. Jelen helyzetben csupán két ilyen dimenziót veszünk figyelembe. Egyfelől a gazdasági centralitást vizsgáljuk, amit a gazdasági teljesítőképesség alapján mérünk, másfelől pedig a hálózati centralitást, amit a kapcsolatok számával közelítünk. A 7.3. ábra mutatja a két mérce közötti összefüggést.

Az ábrán jól látszik, hogy a gazdasági és a hálózati centralitás között pozitív kapcsolat fedezhető fel, a kapcsolat szorossága azonban nem nagyon erős. Épp a kapcsolat e relatív gyengesége veti fel azt a lehetőséget, hogy a centralitást e két dimenzió mentén elkülönülten kezeljük, így a továbbiakban ezt a megkülönböztetést fogjuk alkalmazni a szimulációk során.

A 96 régió könnyebb kezelése érdekében csoportokat hozunk létre mindkét szempont szerint. A csoportok létrehozásának menete a következő: mind a GDP, mind pedig a foksám alapján a régiók olyan csoportját alakítjuk ki, amelyek a GDP és a foksám értékek azonos intervallumába esnek. Így a csoportok nem azonos számosságúak, ugyanakkor a két

⁵Megjegyzendő, hogy a hálózati struktúrával kapcsolatos következtetések természetesen levonhatóak a kalibrált modell alapján is, összehasonlítva a kapott eredményeket a 4. fejezet szimulációival.



7.3. ábra. A gazdasági és hálózati centralitás közötti összefüggés


csoportosítási ismérv alapján homogéneknek tekinthetők. Mindkét csoportosítás esetén kiemelünk három régiót, nevezetesen Ile-de-France régióját Franciaországban, Londont az Egyesült Királyságban és Oberbayernt Németországban, amelyek mind a foksámot tekintve, mind pedig a GDP-t tekintve vezető régiók a mintánkban. E három régió kapja mindkét dimenzióban a vezető régió megjelölést. A többi régiót ezt követően a GDP és a foksám értékek alapján további csoportokba soroljuk: itt már lényeges eltérések jelentkezhetnek a GDP és a foksám szerint besorolás tekintetében, amint az a 7.3. ábrán is jól látható. A csoportosítás részletei a fejezethez tartozó függelék F56 táblázatában találhatóak meg.

7.2.2. Technológiai sokkok dinamikus hatása

A továbbiakban olyan szimulációkat mutatunk be, amelyekben a régiók különböző csoportjait technológiai sokkhatás éri, és megvizsgáljuk a technológiai sokkok hatását a régiók kibocsátására. A szokásos eljárásnak megfelelően egy szórásnyi sokkhatással dolgozunk, ami azt jelenti, hogy a kiválasztott régió saját tudását, vagyis a \mathbf{k} vektor megfelelő elemét ekkora mértékben növeljük. Ez az érték a kalibrált $\hat{\mathbf{k}}$ vektor értékek szórásaként 0,0033. E sokkhatás dinamikus hatását a 4. fejezetben leírt módon szimuláljuk a modellben, majd megvizsgáljuk a kapott eredményeket.

Annak érdekében, hogy a különböző csoportokra elvégzett szimulációk eredménye összevethető legyen, a sokkal érintett régió kiválasztása során a következő módszert alkalmazzuk. Megadjuk, hogy a technológiai sokk mely csoportba tartozó régiót érintsen, ezt követően az adott csoportból véletlenszerűen kiválasztunk egy régiót és szimuláljuk a sokk hatását az általános egyensúlyra. A véletlen kiválasztást 20 alkalommal megismételjük, majd a kapott eredményeket átlagoljuk, így egy hozzávetőleges dinamikát kapunk arra vonatkozóan, hogy milyen hatással jár, ha az adott csoport „tipikus” régióját érinti a technológiai sokkhatás.

Elsőként egy olyan esetet mutatunk be, ahol a sokkhatás a gazdasági centrumokat érinti, vagyis a korábban már kiemelt három régió valamelyikét. A sokk permanens, azaz hatása folyamatosan fennmarad. A 7.4. ábra mutatja az öt vizsgált csoport GDP-jének relatív változását (a kiindulási időszak értékét egységnyinek választottuk.)




7.4. ábra. A gazdasági centrumot érintő technológiai sokk hatása a GDP-re az öt, GDP szerint képzett csoportban

Az ábrán az látható, hogy a centrumot érintő technológiai sokk a legnagyobb hatást magában a centrumban fejt ki, vagyis abban a három régióban, amelyet a gazdasági centrumhoz soroltunk. Ezzel szemben a további négy csoportban a kibocsátás gyakorlatilag nem növekszik, sőt, átmenetileg csökken is. A periférikus régiók (4. és 5. csoport) esetén a kibocsátás abszolút értelemben csökken is.

A továbbiakban elvégeztük ugyanezeket a szimulációkat a további négy csoportot érintő sokkhatások esetén. E szimulációk eredményeit mutatja tömören a 7.5. ábra. Az ábrán az egyes régió-csoportok GDP-jének változását mutatják az oszlopok. A vízszintes tengelyen a csoportosítás aszerint történt, hogy mely régiócsoportot érintette a technológiai sokkhatás. Így az első szaggatott vonaltól balra található oszlopok azt mutatják, hogy az egyes régiócsoportokban (különböző árnyalatú oszlopok) milyen hatást vált ki, ha az első csoport valamely régióját érinti a technológiai sokkhatás.

Először is az látható, hogy a technológiai sokk a legnagyobb hatást jellemzően abban a csoportban fejt ki, amely csoportot a sokk érinti. A többi csoport esetén a GDP csak kis mértékben nő, de sok esetben csökken. Ugyanakkor érdekes tendenciát látunk a technológiai sokkok közvetlen, csoporton belüli hatását illetően: ez a hatás tipikusan akkor magasabb, ha a sokk a centrális régiókat érinti, és kisebb, amikor a periférikus régiókat. Ugyanakkor az is jól látható, hogy a legerősebb régióon belüli hatás nem az 1. csoport, tehát a vezető régiók esetén jelentkezik, hanem akkor, amikor a sokkhatás a 2. csoport valamely régióját érint. Ezek a megállapítások arra mutatnak, hogy a technológiai sokkhatások legnagyobb „megtérülése” a vezető régiókban jelentkezik.




7.5. ábra. A GDP változása az egyes régiócsoportokban különböző csoportokat érintő technológiai sokkhatások esetén, GDP szerinti csoportosításban

Nagyon fontos megállapítások adódnak azonban a csoporton kívüli hatásokat illetően is. Ebből a szempontból azt tapasztaljuk, hogy a régióon kívüli hatások hasonló tendenciát követnek, mint a régióon belüli hatások, csak ellentétes előjellel. Amennyiben a centrális régiókat érinti a technológiai sokkhatás, a periferikus régiók kibocsátása tipikusan csökken a szimulációk eredménye szerint – a centrális régiókban egyfajta elszívó hatás látszik érvényesülni. Ha a technológiai sokk ezzel szemben a periferikus régiókat érinti, úgy a sokkal nem érintett régiók is növekedést mutatnak a GDP-ben. Összhangban az imént említett elszívó hatással, ez az eredmény azt mutatja, hogy a centrális régiók olyan „erővel” bírnak, amely képessé teszi őket arra, hogy a gazdaság bármely pontján jelentkező technológiai haladásból profitáljon. Azt is fontos azonban megjegyeznünk, hogy ez az erő csupán a három legerősebb, régió (Ile-de-France, Oberbayern, London) esetében mutatkozik. A második csoport régiói csupán abban az esetben mutatnak növekedést a GDP-ben, ha ezen régiók valamelyikét érinti a technológiai sokk.

A 7.6. ábra az előzővel teljesen analóg szimulációk eredményeit mutatja. A különbség csupán annyi, hogy a GDP szerinti csoportosítás helyett most a foksám szerint csoportosítjuk a régiókat.

A hálózati struktúra alapján képzett csoportok esetén hasonló kép bontakozik ki, mint a GDP szerint képzett csoportok esetén. A csoporton belüli hatás a GDP-re pozitív, de annál kisebb, minél periferikusabb csoportokat érint a technológiai sokk. A csoporton kívüli hatás szintén követi azt a tendenciát, amit a GDP szerinti csoportosításnál láttunk. Ugyanakkor ennél a csoportosítási módnál az első három csoport valamennyi sokkhatás esetén profitál a technológiai haladásból. Szemben azonban a GDP szerinti csoportosítással, a jelen esetben a csoporton belüli pozitív hatások kisebbek, a csoporton kívüli negatív és pozitív irányú hatások pedig nagyobbak.



7.6. ábra. A GDP változása az egyes régiócsoportokban különböző csoportokat érintő technológiai sokkhatások esetén, foksám szerinti csoportosításban


A technológiai sokk hatásában mutatkozó eltérések arra mutatnak, hogy a foksám szerinti csoportosítás esetén a megfigyelt tendenciák markánsabban jelentkeznek. Ez azzal magyarázható, hogy a technológiai diffúzió paraméterei elsősorban a hálózati struktúrától függenek. Ugyanakkor a modell relevanciáját mutatja az, hogy összehasonlítva a két csoportosítási mód szerinti eredményeket, azt látjuk, hogy a hálózati struktúra közvetlen hatását a diffúziós folyamatokra a hálózatra épülő gazdasági tevékenység árnyalja. Így a parciális hálózati modellek általunk alkalmazott általános egyensúlyi kibővítése releváns hozzáadott értékkel bír.

7.2.3. A technológiai sokk hatása aggregált szinten

Az előző fejezetpontban azt vizsgáltuk, hogy a technológiai sokkhatások milyen hatással járnak a regionális GDP szintjére. Fontos lehet azonban azt is megvizsgálnunk, hogy a vizsgált gazdasági rendszer egészére nézve milyen eredmények adódnak. A továbbiakban az aggregált GDP-re és a GDP régiók közötti szóródására vonatkozó eredményeket mutatjuk be.


A 7.7. ábra mutatja az aggregált GDP alakulását a különböző csoportokat érintő sokkhatások esetén. Jól látható, hogy aggregált szinten attól függően kapunk nagyobb vagy kisebb hatást, hogy a centrális vagy a periferikus régiókat érinti a technológiai sokkhatás. Ez a kép egybevágh azzal, amit a 7.5. ábra alapján is láttunk.

A 7.8. ábra a regionális GDP szintek relatív szórásának alakulását mutatja. Itt azt látjuk, hogy a régiók közötti egyenlőtlenség nagy mértékben növekszik, ha a centrális régiókat érinti a technológiai sokkhatás, és nagyjából változatlan marad, vagy enyhén nő, ha a sokk nem a három centrális régió valamelyikét érinti. Ebből az a tétel következik, hogy a növekedés és



7.7. ábra. Az aggregált GDP alakulása különböző régiócsoportokat érintő technológiai sokkok esetén, GDP szerinti csoportosításban

az egyenlőség között trade-off kapcsolat áll fenn. Minél magasabb aggregált növekedésre törekszünk, annál nagyobb egyenlőtlenséget kell érte vállalni és fordítva: az egyenlőtlenség szinten tartásával alacsonyabb növekedés jár együtt. Ez az eredmény szorosan illeszkedik más korábbi megállapításokhoz a regionális egyenlőtlenség és az innovációs aktivitás vagy aggregált teljesítmény közötti trade-off viszony kapcsán.⁶




7.8. ábra. A regionális GDP értékek szóródásának alakulása különböző régiócsoportokat érintő technológiai sokkok esetén, GDP szerinti csoportosításban

Egy fontos további következtetés az is, hogy a régiók közötti egyenlőtlenség nem csökken érdemben még akkor sem, ha a technológiai sokkhatás a periférikus régiókat érinti. Ez a

⁶Lásd pl. Martin (1999) vagy Meyer (2008) munkáit.

centrális régiók azon tulajdonságából ered, hogy a perifériát érintő technológiai sokkokból is képesek profitálni. Az eddigiekkel teljesen azonos képet kapunk akkor is, ha a régiók csoportosításának alapja nem a GDP, hanem a fokszám.

Érdeemes feltenni még azt a kérdést, hogy elképzelhető-e, hogy a periférikus régiók nagy mértékű támogatása az egyenlőtlenséget csökkenti és az aggregált kibocsátást növeli. Ennek érdekében elvégeztünk egy olyan szimulációt is, ahol a technológiai sokk nagysága nagyobb, mint az eddig használt egy szórás. A sokk nagyságát 1 szórásnyi és 5 szórásnyi értékek között változtattuk. A már ismert struktúrában mutatja az eredményeket a 7.9. ábra, mindössze annyi különbséggel, hogy a vízszintes tengelyen a csoportok most a sokk nagysága szerint kerültek feltüntetésre. A technológiai sokkok valamennyi esetben a régiók ötödik csoportját érintették.



7.9. ábra. A GDP alakulása csoportonként, különböző mértékű technológiai sokkok esetén, GDP szerinti csoportosításban

Az ábráról az látszik, hogy a nagyobb mértékű technológiai sokkhatás a régió saját csoportjában ugyan lényegesen nagyobb hatást generál, azonban a régiók közötti egyenlőtlenséget egyértelműen növeli. A vezető régiók, de még a 3. csoportba tartozó régiók is pozitív növekedést érnek el, ha az ötödik csoport valamely régióját az általunk vizsgált legnagyobb sokkhatás éri.

7.2.4. A hálózati struktúra szerepe

A szimulációk során kapott eredmények rávilágítanak néhány fontos következtetésre a hálózatok struktúráját illetően. Először is azt láttuk, hogy az aggregált növekedés és a regionális egyenlőtlenségek között szétartó kapcsolat van. Ez az eredmény egyrészt fontos adalékul szolgál a közelmúlt fejlesztéspolitikai kísérletei számára, másrészt pedig megerősíti több korábbi kutatás eredményét, amelyek szintén hasonló eredményre jutottak (Varga, 2007; Varga és szerzőtársai, 2010).

Fontos azonban azt is figyelembe vennünk, hogy a vizsgált szimulációk során a hálózati struktúra változatlan. Természetesen a technológiai fejlődés és az ezzel együtt járó gazdasági növekedés a hálózati struktúrát is átrendezi, amivel a modellünk ebben a formájában nem számol, azonban ennek ellenére rámutat a hálózati kapcsolatok változásának fontosságára. A nagy mértékű sokkhatás a periférikus régiókban a GDP jelentős növekedése mellett vélhetően a hálózati hierarchiában elfoglalt helyet is megváltoztatja, így a periférikus régiók mind a gazdasági teljesítmény, mind pedig a hálózati struktúra dimenziójában feljebb lépnek az addigi pozícióhoz képest. Ez azonban az egyenlőtlenség csökkenése mellett a további sokkhatások kibocsátásra gyakorolt hatását is egyenlőbbé teheti.

Így tehát a hálózatok dinamikus fejlődése biztosíthatja a periférikus régiók felzárkózását. Itt ugyanakkor rögtön két lehetőség is adódik. Az egyik lehetőség a technológiai sokkok koncentrálása révén a hálózati fejlődés közvetett elősegítése, amelyről eddig volt szó. A másik lehetőség azonban a hálózati kapcsolatok közvetlen befolyásolása: az együttműködés támogatásával a periférikus régiók még azelőtt képesek lehetnek bekapcsolódni a tudás-áramlás központi folyamataiba, mielőtt a gazdasági teljesítményük ezt önmagában indokolná, vagy előidézné. A hálózati perifériáról a hálózati centrumba történő átkerülés a kedvezőbb technológiai kölcsönhatásoknak köszönhetően lehetővé teszi, hogy a régió kívüli technológiai sokkhatásokból a régió maga is jelentős mértékben profitáljon.

Mindezek mellett egy további fontos megjegyzést is tehetünk, ami a hálózati struktúra globális értelmezése és a gazdasági teljesítmény összefüggésében jelentkezik. Az empirikus tapasztalatok azt mutatják, hogy az általunk vizsgált három országban a régiók közötti tudáshálózatok struktúrája meglehetősen sűrű, így közel áll a Watts-Strogatz modell véletlen hálózataihoz, ugyanakkor, kifejezetten abban az esetben, ha a kapcsolatok súlyozását is figyelembe vesszük, a hálózat erős skálafüggetlenséget is mutat. A hálózati struktúra és a gazdasági teljesítmény között a 4. fejezetben elméleti síkon feltárt és a 6. fejezetben empirikusan is alátámasztott összefüggések alapján ez azt jelenti, hogy a megfigyelt hálózati struktúra mind a Watts-Strogatz, mind pedig a módosított Barabási-Albert modell dimenziójában közel áll a legkedvezőbb gazdasági teljesítményt biztosító struktúrához. Ez az eredmény alátámasztja azokat a megfontolásokat, amelyek Adam Smith munkássága óta a gazdasági önszerveződés és a társadalmi optimum közötti pozitív irányú kapcsolat mellett érvelnek.

8. fejezet

Összegzés

A gazdasági növekedéssel foglalkozó szakirodalom egyik leglényegesebb megállapítása, hogy a hosszú távú növekedés szervesen összekapcsolódik a tudás felhalmozásával, amely tudás számos formában jelenhet meg a gazdasági rendszeren belül (technológia, emberi tőke, fizikai tőkejavak). Alapvető kérdés ugyanakkor, hogy a tudás terjedésében és ezáltal a gazdasági teljesítményben milyen szerepe van azoknak a hálózatoknak és e hálózatok struktúrájának, amelyeket összefoglaló néven tudáshálózatoknak nevezhetünk, és amelyek a gazdaság lokális pontjain megjelenő új tudást hozzáférhetővé teszik a gazdaság egésze számára. A disszertációban alapvetően a tudáshálózatok (és azok struktúrája) szerepének makroökonómiai modellbe integrálásának egy kísérletét mutattam be, majd ennek a kísérletnek különböző empirikus vetületeit vizsgáltam meg.

A modellezéshez szükséges két építőelem, a makromodell és a hálózati struktúra közül az első tulajdonképpen a mainstream közgazdasági szakirodalom által biztosított, míg a második addicionális elemeket igényelt. A hálózatokat illetően a disszertációban egy már elterjedten alkalmazott hálózati modellt, valamint egy részben saját fejlesztésű hálózati modellt alkalmaztam. Az utóbbi alkalmas arra, hogy a valóságban előforduló skálafüggetlen hálózatokat reprodukáljuk a segítségével, még hozzá olyan módon, hogy e skálafüggetlenség mértékét egy paraméter segítségével viszonylag széles skálán határozhatjuk meg.

A dolgozat első fontos következtetéseként azt fogalmaztuk meg, hogy a bemutatott, hálózati kapcsolatokkal bővített általános egyensúlyi modellben a gazdasági szereplőket (vállalatokat) összekötő hálózat struktúrájának markáns hatása figyelhető meg. Egyfelől kimutattuk, hogy a véletlenszerű hálózati struktúrák hatékonyabbak a gazdaság aggregált kibocsátása szempontjából, mint a szabályos hálózatok. Ez egyben azt is jelenti, hogy a sűrű lokális kapcsolatokkal szemben előnyt élveznek azok a struktúrák, amelyekre a rövid elérési utak a jellemzők. Az is kiderült azonban, hogy a véletlenszerű hálózatoknál még kedvezőbb aggregált teljesítményt nyújthat az a gazdasági rendszer, amelyben a szereplőket összekötő hálózati struktúra skálafüggetlen jellemzőkkel bír. Ez az eredmény árnyalja azokat az eredményeket, amelyek a hálózatokra épülő rendszerek hatékonyságát a hálózatok struktúrájának kis világ jellegével hozták összefüggésbe. Az elemzés ebből a szempontból azt

is megmutatja, hogy a gazdasági rendszer explicit figyelembevétele és hozzákapcsolása a hálózati struktúrához addicionális értékkel bír.

Az aggregált teljesítmény és az egyenlőtlenség közötti összefüggés tekintetében is fontos eredmények találhatók. A magasabb teljesítmény rendszerint a gazdaság szereplői egyedi teljesítményének nagyobb szóródásával jár együtt. Ez az összefüggés a modell egy speciális vetületében is megjelenik. Ha ugyanis a gazdasági egységek közötti sokféleséget vizsgáljuk, azt mondhatjuk, hogy az egységek közötti hálózati kapcsolatok éppen arra szolgálnak, hogy a más szereplőknél található eltérő információkat vagy tudásbázist hozzáférhetővé tegyék: ennél fogva a szélesebb körű hálózati kapcsolatok az információk és a felhasználható tudás diverzitásának növekedéséhez vezetnek. A bemutatott modell vizsgálata arra mutat rá, hogy minél markánsabb a gazdasági egységek közötti sokféleség (azaz minél kevésbé helyettesíthető egymással a különböző forrásokból érkező tudás), egyrészt annál nagyobb lesz az elérhető kibocsátási szint, másrészt pedig annál markánsabb a tudáshálózatok struktúrájának az a szerepe, amelyet az előző bekezdésben foglaltunk össze.

A dolgozat egy további részében azt vizsgáltuk, hogy a hálózati struktúrák milyen szerepet játszanak a tudás diffúziójában. Itt arra a következtetésre jutottunk, hogy a diffúzió végeredménye szempontjából (vagyis abban a tekintetben, hogy végső soron milyen hatást gyakorolnak a technológiai sokkok a gazdaság aggregált szintű kibocsátására) nem találhatók markáns eltérések a hálózati struktúra kapcsán, az egyedüli kivételt a szélsőségesen skálafüggetlen hálózatok esetén tapasztalhattuk, amikor is az aggregált hatás attól függően változik, hogy a technológiai sokk centrális vagy periférikus helyzetben lévő vállalatot érint.

Amennyiben azonban a technológiai diffúzió folyamatát vizsgáljuk, úgy az egyes hálózati struktúrák közötti különbség markánsabbá válik. A véletlenszerűség növekedésével a technológiai sokk hatása a rendszer egészében kisebb mértékű, ugyanakkor a növekedés hamarabb indul meg, hamarabb válik érzékelhetővé a rendszer egészének szintjén. A skálafüggetlenség növekedése ezzel szemben pozitívan hat mind a végső teljesítmény-növekedésre, mind pedig az időbeli lefutásra, amely utóbbi alatt azt értjük, hogy a növekedés hirtelen, nagyobb mértékben jelentkezik. Kivételt ez alól az az eset jelent, amikor a technológiai sokkhatás a gazdaság centrális szereplőit érinti: ekkor a legnagyobb hatást a véletlenszerűbb hálózatok esetén figyelhetjük meg, ugyanakkor a dinamika ebben az esetben is lassabb.

Ezek az eredmények ismét rámutatnak arra a fontos összefüggésre, amelyet az aggregált teljesítmény és az egyenlőtlenség között tapasztalunk. A technológiai változásnak (technológiai sokkoknak) akkor figyelhetjük meg a legnagyobb hatását, ha a hálózati struktúra nagyfokú aszimmetriát (egyenlőtlenséget) mutat. Így tehát egy általánosabb szinten egy rendszer teljesítménye és a rendszer elemei közötti különbségek (egyenlőtlenség) között ellentétes irányú, trade-off kapcsolat figyelhető meg. Ez a megállapítás ugyanakkor egy távolabbi összefüggésre is felhívja a figyelmet. A hálózatokkal kapcsolatos szakirodalom rávilágít arra, hogy a legtöbb valós hálózat skálafüggetlen tulajdonságokkal rendelkezik.

Bár ezt nem állíthatjuk biztosan, ezek alapján úgy tűnik, hogy ezek a skálafüggetlen struktúrák egyfajta evolúciósan stabil állapotot tükröznek, ami azt jelenti, hogy rendszerint ezek a struktúrák biztosítják az adott rendszer legjobb illeszkedését az adott környezeti feltételekhez. Elemzésünk azt mutatja, hogy legalábbis a gazdasági rendszerek esetében ezt az evolúciós stabilitást megerősíti az az eredmény, hogy a skálafüggetlen rendszerek azok, amelyek a legjobb teljesítményt adják.

A dolgozat pozitív elméleti eredményeit követően olyan empirikus elemzéseket mutattam be, amelyek a modell egy fontos alapelemének, illetve főbb következtetéseiének relevanciáját vizsgálták. Az empirikus vizsgálat az elemzés fókuszát a vállalatokról, mint releváns gazdasági egységekről a régiókra helyezte át.

Elsőként a korábban alkalmazott elméleti modell egyik központi elemét vizsgáltam, amely a hálózati kapcsolatokon keresztül hozzáférhető külső tudás és az adott gazdasági egység termelékenysége közötti kapcsolatot írja le. Az első vizsgálatok azt mutatják, hogy ez a kapcsolat a nem várt és kontra-intuitívnek nevezhető negatív előjelű. Pont az intuícióval ellentétes eredmények miatt azonban további vizsgálatokat mutattam be, egyfelől az elemzésbe bevont változók adekvát korrekciójával, másrészt pedig a modell megfelelő értelmezésével. Az első módszer kedvező, de nem túl meggyőző eredményekhez vezetett. A második módszer viszont azt mutatja, hogy a vizsgált empirikus hálózatok nem véletlenül mutatják a negatív összefüggést a külső tudás és a termelékenység között. Az adatbázisba vont régiók közötti hálózat struktúrája ugyanis erősen skálafüggetlennek tekinthető, ami azt jelenti, hogy néhány régió rendkívül sok külső kapcsolattal rendelkezik, a többség azonban lényegesen kevesebbel. Emellett erős korreláció figyelhető meg a gazdasági teljesítmény (esetünkben a termelékenység) valamit a kapcsolatok száma között: tipikusan azok a régiók rendelkeznek több külső kapcsolattal, amelyek magasabb termelékenységgel is jellemezhetőek. Ez ugyanakkor azt is jelenti, hogy a periférikus régiók tipikusan a centrális régiókhoz kapcsolódnak és így egyszerre lesznek jellemezhetőek alacsony termelékenységgel és magas szintű külső tudással. Az elvégzett szimulációk azt mutatják, hogy a vizsgált elméleti modell elegendően erős skálafüggetenség mellett reprodukálja ezt a jelenséget, így tehát az empirikus tapasztalatok egybevágóan modellünkkel, egészen pontosan rámutatnak arra is, hogy a vizsgált hálózati struktúra az elméletileg lehetséges skála mely tartományában található.

A modell e központi tényezőjének vizsgálatát követően a legfontosabb elméleti következtetés empirikus tesztelését végeztem el, nevezetesen, hogy a hálózati struktúrát leíró egyes mutatószámok hatása kimutatható-e a gazdasági teljesítményben. Ezek az eredmények pozitívak, amelyek megerősítik az elméleti modell eredményeit: a véletlenszerűség és a skálafüggetlenség esetében egyaránt sikerül kimutatni a pozitív kapcsolatot a gazdasági teljesítmény és a hálózati mutatószámok között. A vizsgálatnak ez a része azonban további megfontolásokat is igényel. A kapott pozitív eredmények ellenére nem világos, hogy a megfigyelt kapcsolat a hálózati struktúra és a gazdasági teljesítmény tekintetében milyen mértékben vezethető vissza az elméleti modellben tárgyalt összefüggésekre. Minthogy az

alkalmazott módszertan csupán a kapcsolat létezését igazolja, egyáltalán nem lehetünk biztosak abban, hogy ennek a kapcsolatnak mi az iránya. Az elméleti modell ugyan sugallja a hálózati struktúra felől a gazdasági teljesítmény irányába mutató kapcsolatot, ugyanakkor a fordítottja is könnyen elképzelhető: a gazdasági tevékenység változása (fejlődése) vezetett a megfigyelt strukturális változásokhoz. Ugyanakkor az is elképzelhető, hogy mindössze átkorrelációról van szó, vagyis a gazdasági teljesítmény és a hálózati struktúra változásait valamilyen külső, jelen esetben exogénnek tekinthető tényező befolyásolja.

Ezt követően az elméleti modell és az empirikus tapasztalatok integrálása segítségével egy, az Európai Unió három vezető gazdasága (Németország, Egyesült Királyság, Franciaország) adatai alapján kalibrált modellt vizsgáltam meg. A szimulációk során azt mutattam be, hogy a disszertációban rögzített modellezési keret alkalmas lehet arra, hogy olyan fejlesztéspolitikai hatásvizsgálatokat végezzünk, amelyek explicit módon figyelembe veszik a hálózati kapcsolatok szerepét a technológiai diffúzió során. A szimulációk arra mutatnak rá, hogy a technológiai sokkhatások különböző hatást fejtenek ki az egyes régiókban attól függően, hogy a sokkhatás centrális vagy periférikusabb régiókat érintenek. Az egyik legfőbb tapasztalat az, hogy a (gazdasági vagy hálózati szempontból) centrális helyzetben lévő régiók még akkor is tudnak profitálni a technológiai változásokból, ha az a periférikus régiókat érinti, ugyanakkor a periférikusabb régiókban egyfajta elszívó hatás érvényesül: itt csak abban az esetben jelent előrelépést egy technológiai sokkhatás, ha az közvetlenül az adott régiót érinti. Az is megfigyelhető, hogy a technológiai sokkok (vagy adott esetben az irányított kutatás-fejlesztési támogatások) legnagyobb megtérülése akkor adódik, amikor ez a sokkhatás a centrális helyzetben lévő régiókat érinti. Ez a megállapítás jól rímel azokkal a korábbi megfigyelésekkel, ami az egyenlőtlenség és a teljesítmény közötti szétartó kapcsolatot mutatták. Itt ugyanaz látható, csupán dinamikus szemléletben. A magasabb megtérülés, a nagyobb teljesítmény úgy érhető el, ha ezzel együtt megengedjük az egyenlőtlenség növekedését is. A centrális régiók előrelépése az imént említett elszívó hatáson keresztül a periférikus régiók teljesítményét csökkenti vagy csak kisebb mértékben növeli, így bár az aggregált szintű teljesítmény a lehető legnagyobb, a régiók közötti egyenlőtlenség növekedik.

Fontos azonban kiemelni, hogy a kalibrált modell, bár lényeges meglátásokat tükröz, inkább csak szemléltető jellegű: alkalmas arra, hogy segítségével bemutassuk a hálózati kapcsolatok explicit modellezéséből fakadó addicionális meglátásokat, azonban egy komolyabb hatáselemzéshez nyilvánvalóan egy továbbfejlesztett, cizelláltabb modell kifejlesztése szükséges.

A dolgozatban kapott pozitív eredmények ellenére mindenképpen meg kell jegyeznünk a bemutatott modell és elemzési keretek korlátait. Először is, a bemutatott modell rendkívül egyszerű, legalábbis ami a makroökonómiai vetületeket illeti. Az imént kiemeltük, hogy komolyabb alkalmazások esetén a modell e részének kibővítése elkerülhetetlen. Részben a kínálatoldali szemlélet árnyalására lehet szükség részletesebb keresletoldali hatások beépítésével (fejlesztéspolitikai szempontból a gazdaságpolitikai akció- és reakciófüggvények

mindenképpen lényeges pontot jelentenek ebből a szempontból), másrészt pedig érdekes kérdés lehet annak vizsgálata, hogy a monopolisztikus versenytől eltérő piaci struktúrák esetén milyen következtetések adódnak. Ez különösképpen azért fontos, mert a hálózati kapcsolatok és a piaci struktúra között lényegi összefüggések feltételezhetőek, így a piaci szerkezet modellezése kapcsán az itt vázolt hálózatelméleti megközelítés jelentős hozzáadott értékkel bírhat. A piaci struktúrák hálózati szemléletű vizsgálata egyben azt a lehetőséget is felveti, hogy az információ-áramlási rendszerek modellbe építésével a makroszinten jelentkező rugalmatlanságok és sűrűlódások jelenségét egy új aspektusból tárgyaljuk.

Másodszor, a disszertációban alkalmazott két hálózati szemléletmód (vállalati és regionális hálózatok) a kettő összebékítésére tett erőfeszítések ellenére is jelentős dualitást hordoz magában. Egy fontos lépés lenne, ha az elméleti vizsgálatokat ki tudnánk egészíteni a regionális szemléletű modellezési eszközökkel. Erre kitűnő lehetőséget ad az elterjedten alkalmazott SCGE (térbeli számítható általános egyensúlyi) modellezés: itt a regionális dimenziót nem csupán a régiók között felvázolt tudáshálózati struktúra adja, hanem a régiók közötti gazdasági kapcsolatok explicit modellezése is. Egy ilyen integrált hálózati-SCGE modellel az empirikus vizsgálatoknak megfelelő, azokkal konzisztens elméleti modell alkotható, ami így alkalmas lehet a hatáselemzések elvégzésére.

Harmadszor pedig, kiegészítve az előző megjegyzést, az empirikus vizsgálatok is kibővíthetőek: ehhez a regionális dimenzió mellett a vállalatok közötti tudáshálózatok feltérképezésére van szükség. A disszertációban hangsúlyozottan azért szerepelt a regionális dimenzió, mert az ehhez szükséges adatforrások adottak és a szükséges adatbázis viszonylag könnyen felépíthető. A vállalati szintű hálózatok felépítése nagyobb munkát igényel, azonban az OECD által biztosított szabadalmi adatbázisokban rendelkezésre áll az a lehetőség, hogy egy ilyen hálózatot is felépítsünk. Így a most közölt empirikus és elméleti eredmények egymással konzisztens módon összevethetőek lesznek.

Összefoglalva a dolgozat fő gondolati ívét és legfontosabb megállapításait néhány, az itt alkalmazott gondolati kereteken lényegesen túlmutató gondolattal zárnám a disszertációt. A hálózatelméleti munkák fő sodorvonalához illeszkedve sikerült megmutatni, hogy a hálózatok és a hálózati struktúrák szerepe a gazdasági működés fontos részét képezik. Így a dolgozat mondanivalója jól illeszkedik abba a gondolatba, amelyet Barabási Albert-László fogalmazott meg a hálózatokkal kapcsolatban: úgy tűnik, hogy ezek a struktúrák az univerzum lényegi szervezőerejéről árulkodnak. Ebből a szempontból könnyen elképzelhető, hogy a gazdasági rendszerek evolúciója és az élet más területein megfigyelhető evolúciós folyamatok hasonló mozgatóerőkre, analóg folyamatokra vezethetőek vissza. A dolgozat egyik fontos megállapítása volt a sokféleség pozitív szerepe a gazdasági teljesítményben: a tudomány más területeiről vett ismeretanyagok egy ilyen szélesebb perspektívában lényegi ösztönző erővel bírhatnak olyan gazdasági folyamatok és tendenciák felfedezésében, amelyek eleddig rejtve maradtak. Amennyiben ez a disszertáció csak egy kicsiny lépésként is ebbe az irányba mutat, úgy azt gondolom, hogy a benne foglalt erőfeszítések már megtérültek.

Irodalomjegyzék

Abdih Y., Joutz, F. (2005): Relating the Knowledge Production Function to Total Factor productivity: An Endogenous Growth Puzzle. IMF Working Papers, 05/74, International Monetary Fund.

Abrahamson, E., Rosenkopf, L. (1997): Social Network Effects on the Extent of Innovation Diffusion: A Computer Simulation. *Organization Science*, 8(3) pp. 289-309.

Adolfson, M., Laseen, S., Linde, J., Villani, M., (2007): Bayesian estimation of an open economy DSGE model with incomplete pass through. *Journal of International Economics*, 72(2) pp. 481-511.

Aghion, P., Howitt, P. (1992): A Model of Growth Through Creative Destruction. *Econometrica*, 60 pp- 323-351.

Almeida, P., Kogut, B. (1999): Localization of knowledge and the mobility of engineers. *Management Science*, 45 pp. 905-917.

Amato, J., Laubach, T. (2003): Estimation and control of an optimization based model with sticky prices and wages. *Journal of Economic Dynamics and Control*, 27(7) pp. 1181-1215.

Anselin, L., Varga, A., Acs, Z.J. (1997): Local Geographic Spillovers between University Research and High Technology Innovations. *Journal of Urban Economics*, 42(3) pp. 422-448.

Arrow, K.J. (1962): The economic implications of learning by doing. *Review of Economic Studies*, 29 pp. 166-173.

Arrow, K.J. (1994): The Production and Distribution of Knowledge. In: Silverberg, G., Soete, L. (eds.): *The Economics of Growth and Technical Change*, Edward Elgar, pp. 9-19.

Attewell, P. (1992): Technology Diffusion and Organizational Learning: The Case of Business Computing. *Organization Science*, 3 pp. 1-19.

Audretsch, D.B., Feldman, M.P. (1996): R&D Spillovers and the Geography of Innovation and Production. *American Economic Review*, 86(4) pp. 253-273.

Baksa, D., Benk, Sz., Jakab, M. Z. (2009): A Költségvetési Tanács DSGE modelljének rövid leírása. Magyar Köztársaság Költségvetési Tanácsa. Web: www.mkkt.hu/download/000/035/Modelleírás_Függelék.pdf

- Bala, V., Goyal, S. (2000): A Noncooperative Model of Network Formation. *Econometrica*, vol. 68(5), pp. 1181-1230.
- Balconi M., Breschi S., Lissoni, F. (2004): Networks of inventors and the role of academia: An exploration of Italian Patent data. *Research Policy*, 33 pp. 127-145.
- Barabási, A.L. (2002): *Behálózva. A hálózatok új tudománya. Hogyan kapcsolódik minden egymáshoz és mit jelent ez a tudományban, az üzleti és a mindennapi életben.* Magyar könyvklub, Budapest.
- Barabási, A.L. (2003): *Linked: How Everything is Connected to Everything Else what It Means for Business, Science and Everyday Life.* Penguing Group, USA.
- Barabási, A.L., Albert, R. (1999): Emergence of scaling in random networks. *Science*, 286 pp. 509-512.
- Barabási, A.L., Albert, R., Jeong, H. (2000): Scale-free characteristics of random networks: The topology of the world wide web. *Physica A*, 281, pp. 69-77.
- Barro, R., Sala-i-Martin, X. (1991): Convergence across States and Regions. *Brookings Paper of Economic Activity*, pp. 107-182.
- Barro, R., Sala-i-Martin, X. (1992): Convergence. *Journal of Political Economy*, 100 pp. 223-251.
- Barro, R., Sala-i-Martin, X. (1995): *Economic Growth.* McGraw Hill, New York.
- Becker, G.S. (1964): *Human Capital. A theoretical and Empirical Analysis, with Special Reference to Education.* National Bureau of Economic Research New York, Columbia University Press, New York and London.
- Biggs, N., Lloyd, E., Wilson, R. (1986). *Graph Theory, 1736-1936.* Oxford University Press.
- Bollobás, B. (2001): *Random Graphs.* (2nd Edition), Cambridge University Press.
- Boschma, R., Eriksson, R., Lindgren, U. (2009): How does labour mobility affect the performance of plants? The importance of relatedness and geographical proximity. *Journal of Economic Geography*, 9(2), pp. 169-190.
- Breschi, S., Lissoni, F. (2003): Mobility and social networks: localised knowledge spillovers revisited. CESPRI, Working Paper nr. 142.
- Buchanan, M. (2003): *Nexus, avagy "kicsi-a-világ". A hálózatok úttörő tudománya.* Typotex, Budapest.
- Burris, V. (2005): Interlocking directorates and political cohesion among corporate elites. *American Journal of Sociology*, 111 pp. 249-283.
- Callois, J.M., Angeon, V. (2004): On the role of social capital on local economic development: an econometric investigation on rural employment areas in France. In: 78th Conference of Agricultural Economics Society. Agricultural Economics Society, Imperila College, London.
- Cantner, U., Graf, H.(2006): The Network of Innovators in Jena: An Application of Social Network Analysis. *Research Policy*, 35 pp. 463-480.

- Carayol, N., Roux, P. (2009): Knowledge flows and the geography of networks: A strategic model of small world formation. *Journal of Economic Behavior & Organization*, 71(2), pp. 414-427.
- Carter, M. (2001): *Foundations of Mathematical Economics*. MIT Press, Cambridge, MA.
- De Carvalho, A.J., Saur-Amaral, I., Marques, M.J. (2006): Cooperation Networks and Regional Development – Case of Multisectoral Partnership for Innovation. In: Cooke, P., Piccaluga, A. (eds.): *Regional Development in the Knowledge Economy*. Routledge.
- Castells, M. (2000): *The Rise of the Network Society*. Blackwell Publishing, Malden, MA.
- Chakrabarti A.K., Dror, I., Eakabuse, N. (1993): Interorganizational Transfer of Knowledge an Analysis of Patent Citations of a Defense Firm. *IEEE T. Eng. Manage.* 40 pp. 91-94.
- Chen C.M., Hicks, D. (2004): Tracing knowledge diffusion. *Scientometrics*, 59 pp. 199-211.
- Christoffel, K., Coenen, G., Warne, A. (2008): The new area-wide model of the euro area - a micro-founded open-economy model for forecasting and policy analysis. Working Paper Series 944, European Central Bank.
- Cohen, W.M., Levinthal, D.A. (1990): Absorptive capacity: A new perspective on learning and innovation. *Administrative Science Quarterly*, 35(1) pp. 128-152.
- Cohen, W.M., Levinthal, D.A. (1989): Innovation and Learning: The Two Faces of R&D. *Economic Journal*, 99(397) pp. 569-596.
- Coleman, J.S. (1990): *Foundations of Social Theory*. Cambridge MA, Belknap Press of Harvard University.
- Cooke, P. (2005): Regional Knowledge Capabilities and Open Innovation: Regional Innovation Systems and Clusters in the Assymmetric Knowledge Economy. In: Breschi, S., Malerba, F. (eds.): *Clusters, Networks and Innovation*. Oxford University Press, Oxford, UK
- Côte, S., Healy, T. (2001): *The Well-Being of Nations: the Role of Human and Social Capital*. Paris, OECD.
- Cowan, R. (2005): Network models of innovation and knowledge diffusion. In: Breschi, S., Malerba, F. (eds.): *Clusters, Networks and Innovation*. Oxford University Press, Oxford, pp. 29-53.
- Cowan, R., Jonard, N. (2004): Network structure and the diffusion of knowledge. *Journal of Economic Dynamics and Control*, 28(8) pp. 1557-1575.
- Cowan, R., Jonard, N., Zimmermann, J.B. (2006): Evolving networks of inventors. *Journal of Evolutionary Economics*, 16(1) pp. 155-174.
- Davies, S. (1979): *The Diffusion of Process Innovations*. Cambridge University Press, Cambridge.
- Davis, G.F., Yoo, M., Baker, W.E. (2003): The small world of the American corporate elite, 1981-2001. *Strategic Organization*, 1 pp. 301-326.

- Derbyshire J., Chou Y., Gardiner B., Stenning J., Waights S. (2010): Estimating the Capital Stock for the NUTS2 Regions of the EU27. Research based on a pilot study for the European Commission, DG Regional Policy. *Cambridge Econometrics*, March.
- Dib, A., (2001): An Estimated Canadian DSGE Model with Nominal and Real Rigidities. Working Papers 01-26, Bank of Canada.
- Dixit, A.K., Stiglitz, J.E. (1977): Monopolistic Competition and Optimum Product Diversity. *American Economic Review*, 67(3) pp. 297-308.
- Dorogovtsev, S.N., Mendes, J.F.F. (2003): *Evolution of networks: from biological nets to the Internet and WWW*. Oxford University Press, Oxford
- Durkheim, E. (1893): *De la division du travail social, étude sur l'organisation des sociétés supérieures*. Paris, Alcan. Magyarul: A társadalmi munkamegosztásról. Ford. Csákos Mihály, Budapest, Osiris, 2001.
- Ejermo, O., Karlsson, C., (2004): Spatial Inventor Networks As Studied by Patent Coinventorship. Working Paper Series in Economics and Institutions of Innovation 17, Royal Institute of Technology, CESIS - Centre of Excellence for Science and Innovation Studies.
- Ellis, P., Hepburn, G., Oppenheim, C. (1993): Studies on Patent Citation Networks. *Journal of Documentation*, 34(1) pp.12-20.
- Erceg, C.J., Guerrieri, L., Gust, C. (2006): SIGMA: a new open economy model for policy analysis. International Finance Discussion Papers 835, Board of Governors of the Federal Reserve System, US.
- Erdős, P. Rényi, A. (1959): On Random Graphs I. *Publ. Math*, 6 pp. 290-297.
- Euler, L. (1741): Solutio problematis ad geometriam situs pertinentis. *Commentarii academiae scientiarum Petropolitanae*, 8, pp. 128-140.
- Feldman, M.P. (1994): *The Geography of Innovation*. Boston, Kluwer Academic Publisher.
- Feldman, M. P. (1999): The New Economics of Innovation, Spillovers and Agglomeration: A Review of Empirical Studies. *Economics of Innovation and New Technology*, 8(1) pp. 5-25.
- Feldman, M.P., Lichtenberg, F.R. (1997): The Impact and Organization of Publicly-Funded Research and Development in the European Community. NBER Working Papers 6040, National Bureau of Economic Research, Inc.
- Florida, R. (1995): Toward the Learning Region. *Futures*, 27(5) pp. 527-536.
- Garlaschelli, D., Loffredo, M.I. (2005): Structure and evolution of the world trade network. *Physica A*, 355 pp. 138-144.
- Giuliani, E., Bell, M.(2005): The micro-determinants of meso-level learning and innovation: evidence from a Chilean wine cluster. *Research Policy*, 34 pp. 47-68.
- Gort, M., Klepper, S. (1982): Time Paths in the Diffusion of Product Innovations. *Economic Journal*, 92 pp. 630-653.

- Granovetter, M.S. (1973): The Strength of Weak Ties. *American Journal of Sociology*, 78(6) pp. 1360.
- Granovetter, Mark (1983): The Strength of Weak Ties: A Network Theory Revisited. *Sociological Theory*, 1 pp. 201-233.
- Gress, B., (2010): Properties of the USPTO patent citation network: 1963-2002. *World Patent Information*, 32(1) pp. 3-21.
- Griliches Z. (1990): Patent statistics as economic indicators: a survey. *Journal of Economic Literature*, 20(4) pp. 1661.
- Griliches, Z. (1957): Hybrid Corn: An Exploration in the Economics of Technological Change. *Econometrica*, 25 pp. 501-522.
- Griliches, Z. (1979). Issue in Assessing the Contribution of R&D to Productivity Growth. *Bell Journal of Economics*, 40(3-4) pp. 251-258.
- Grossman, G.M., Helpman, E. (1991): Quality Ladders and Product Cycles. *Quarterly Journal of Economics*, 105 pp. 557-586.
- Griliches, Z. (1992): The Search for R&D Spillovers. *Scandinavian Journal of Economics*, 94(0) pp. S29-47.
- Grossman, G.M., Helpman, E. (1994): Endogenous Innovation in the Theory of Growth. *Journal of Economic Perspectives*, 8 pp. 23-44.
- Guesnier, B. (1998): Innovative Milieu and regional Development. *Cybergeo : European Journal of Geography*. Dossiers, Fragments of regional science in honour of Jean Paelinck, document 48.
- Harrison, R., Nikolov, K., Quinn, M., Ramsay, G., Scott, A., Thomas, R. (2005): The Bank of England Quarterly Model. London: Bank of England.
- Heston, A., Summers, R., Aten, B. (2009): Penn World Table Version 6.3, Center for International Comparisons of Production, Income and Prices at the University of Pennsylvania, August 2009.
- Jackson, M.O., Wolinsky, A. (1996): A Strategic Model of Social and Economic Networks. *Journal of Economic Theory*, 71(1) pp. 44-74.
- Jacobs, J.(1969): *The Economies of Cities*. New York: Random House.
- Jaffe, A.B. (1986): Technological Opportunity and Spillovers of R&D: Evidence from Firms' Patents, Profits, and Market Value. *American Economic Review*, 76(5), pp. 984-1001.
- Jaffe, A.B. (1989): Real Effects of Academic Research. *American Economic Review*, 79(5) pp. 957-970.
- Jaffe, A.B., Trajtenberg, M. (2002): *Patents, Citations and Innovations: A Window on the Knowledge Economy*. MIT Press, Cambridge, MA.

- Jaffe, A.B., Trajtenberg, M., Henderson, R. (1993): Geographic Localization of Knowledge Spillovers as Evidenced by Patent Citations. *The Quarterly Journal of Economics*, 108(3) pp. 577-598.
- Jakab, Z.M., Világi, B. (2008): An estimated DSGE model of the Hungarian economy. MNB Working Papers 2008/9, Magyar Nemzeti Bank.
- Johansson, B., Forslund, U. (2008): The analysis of location, co-location and urbanization economies. In: Karlsson, C. (ed.): *Handbook of Research on Cluster Theory*. Edward Elgar, UK.
- Jung, C.G. (1993): *Bevezetés a tudattalan pszichológiájába*. 3. kiad. Európa, Budapest.
- Kaldor, N. (1966): Marginal Productivity and the Macro-Economic Theories of Distribution: Comment on Samuelson and Modigliani. *The Review of Economic Studies*. 33(4) pp. 309-319.
- Karinthy, F. (1929): *Minden másképpen van (Ötvenkét vasárnap)*. Athenaeum, Irodalmi és Nyomdai Rt., Budapest.
- Karki M.M. (1997): Patent citation analysis: a policy analysis tool. *World Patent Inf.* 19 pp. 269-272.
- Kimball, M.S. (1995): The Quantitative Analytics of the Basic Neomonetarist Model. *Journal of Money, Credit and Banking*, 27(4) pp. 1241-1277.
- Koopmans, T.C. (1963): On the Concept of Optimal Economic Growth. Cowles Foundation Discussion Papers 163, Cowles Foundation, Yale University.
- Krugman, P. (1991): *Geography and Trade*. The MIT Press: Cambridge, MA.
- Kruzslicz, F., Sebestyén, T., Parag, A. (2010): Kapcsolati háló elemzés az európai szabadalmi adatbázis alapján. Konferencia előadás 7. Országos Gazdaság-informatikai Konferencia, Pécs, 2010. november 26-27.
- Li, X., Chen, H., Huang, Z., Roco, M. (2007): Patent citation network in nanotechnology (1976-2004). *Journal of Nanoparticle Research*, 9(3) pp. 337-352.
- Liebeskind, J.P., Oliver, A.L., Zucker, L.G., Brewer, M.B. (1995): Social Networks, Learning, and Flexibility: Sourcing Scientific Knowledge in New Biotechnology Firms. ISSR Working Papers in the Social Sciences, 7994-95 6(4).
- Lucas, R.E. (1988): On the Mechanics of Economic Development. *Journal of Monetary Economics*, 22 pp. 3-42.
- Lucas, R.E. (1990): Supply Side Economics: An Analytical Review. *Oxford Economic Papers*, 42 pp. 293-316.
- Lucas, R.E. (1993): Making A Miracle. *Econometrica*, 61 pp. 251-272.
- Luce, R.D., Perry, A.D. (1949): A method of matrix analysis of group structure. *Psychometrika*, 14(1) pp. 95-116.

- Maddala, G.S. (2001): *Econometrics*. Third Edition, Wiley.
- Maggioni, M.A., Uberti, T.E., (2010): Networks and geography in the economics of knowledge flows. Cognitive Science and Communication Research Centre Working Paper, CSCC WP 01/10.
- Maggioni, M.A., Uberti, T.E. (2009): Network analysis of an Industrial District. Knowledge and Financial Flows in Castelgoffredo, paper presented at the 2nd SNAID International Workshop, 11 December 2009, Milano.
- Maggioni, M.A., Uberti, T.E. (2006): International networks of knowledge flows: an econometric analysis. *Papers on Economics and Evolution*, 2005-19, Max Planck Institute of Economics, Evolutionary Economics Group.
- Maggioni, M.A., Uberti, T.E., Usai, S. (2010): Treating patent as relational data: Knowledge transfers and spillovers across Italian provinces. *Industry and Innovation* forthcoming. Egy korábbi verzió elérhető: DISEIS Working Paper 0802, Vita e Pensiero, Milano (2008)
- Marshall, Alfred (1890): *Principles of Economics*. Macmillan, London.
- Martin, P. (1999): Are European regional policies delivering? *EIB Papers*, IV(2), pp. 10-23.
- Mendoza, G.E. (1991): Real Business Cycles in a Small Open Economy. *The American Economic Review*, 81 pp. 797-818.
- Meyer, D. (2008): Equity and efficiency in regional policy. *Periodica Mathematica Hungarica*, 56(1) pp. 105-119.
- Morrison, A. (2003): Gatekeepers of Knowledge within Industrial Districts: Who They Are, How They Interact. *Regional Studies*, 42 pp. 817-835.
- Mukoyama, T. (2004): Diffusion and Innovation of New Technologies under Skill Heterogeneity. *Journal of Economic Growth*, 9(4), pp. 451-479.
- Nelson, R.R., Winter, S. (1982): *An Evolutionary Theory of Economic Change*. The Belknap Press of Harvard University, London.
- Nonaka, I. (1994): A Dynamic Theory of Organizational Knowledge Creation. *Organizational Science*, 5(1) pp. 14-37.
- Nooteboom, B. (2004): *Inter-Firm Collaboration. Learning and Networks*. Routledge.
- OECD, REGPAT Database, October 2009
- Oppenheim C. (2000): Do Patent Citations Count? In: Cromin, B., Atkins, H.B (eds.): *The Web of Knowledge*. Information Today, Inc, Medford, pp. 405-432.
- Pakes A., Griliches, Z. (1984): Patents and the R&D at the firm level: a first look. In: Griliches, Z. (ed.): *R&D, patents and productivity*. Chicago University Press, Chicago, pp. 390-409.
- Parag A, Sebestyén, T. (2009): The Evolution of Patent Innovator Networks: The Dynamics of Structural Characteristics and Link Formation. *Networks, Power and Relations*. First

International NPR Workshop Catholic University of the Sacred Heart, 16-17 September, Milan, Italy

Parrilli, M.D. (2006): Cluster trajectories in developing countries: a stage and eclectic approach to survival clusters in Central America. In: Pitelis, Sugden, Wilson (eds.): *Clusters and Globalization. The development of urban and regional economies*, Edward Elgar, UK.

Polányi, M. (1967): *Tacit Knowledge*. Anchor Book, New York.

Ramsey, F. (1928): A Mathematical Theory of Saving. *Economic Journal*, 38 pp. 543-549.

Ratto, M., Roeger, W., Veld, Jan in 't (2009): QUEST III: An estimated open economy DSGE model of the euro area with fiscal and monetary policy. *Economic Modelling*, 26(1) pp. 222-233.

Ricardo J.C., Jaffe, A.B. (1993): How High are the Giants' Shoulders: An Empirical Assessment of Knowledge Spillovers and Creative Destruction in a Model of Economic Growth. NBER Working Papers 4370, National Bureau of Economic Research, Inc.

Ricardo, D. (1991): *A politikai gazdaságtan és az adózás alapelvei*. Közgazdasági és Jogi Könyvkiadó, Budapest.

Rogers, E.M. (2003): *Diffusion of Innovations*. 5th Edition, Free Press, New York.

Rogers E.M., Medina, U.E., Rivera, M.A., Wiley, C.J. (2005): Complex adaptive systems and the diffusion of innovations. *Pub Sector Innov J*, 10 pp. 1-26.

Romer, P. (1987): Crazy Explanation for the Productivity Slowdown. NBER Macroeconomic Annual, MIT Press, Cambridge.

Romer, P.M. (1988): Capital Accumulation In The Theory Of Long Run Growth. RCER Working Papers 123, University of Rochester - Center for Economic Research.

Romer, P.M. (1990): Endogenous Technological Change. *Journal of Political Economy*, 98 pp. S71-102.

Romer, P.M. (1994): The Origins of Economic Growth. *Journal of Economic Perspectives*, 8 pp. 3-22. o.

Rotemberg, J.J., Woodford, M. (1993): Dynamic General Equilibrium Models with Imperfectly Competitive Product Markets. NBER Working Papers 4502, National Bureau of Economic Research, Inc.

Rotemberg J.J., Woodford, M. (1998): Interest-Rate Rules in an Estimated Sticky Price Model. NBER Working Papers 6618, National Bureau of Economic Research, Inc.

Saxenian, A.L. (1994): *Regional Advantage: Culture and Competition in Silicon Valley and Route 128*. Harvard University Press, Cambridge, MA.

Saxenian, A.L. (1999): *Silicon Valley's New Immigrant Entrepreneurs*. Public Policy Institute of California, San Francisco.

Schultz. T.W. (1983): *Beruházás az emberi tőkébe*. Közgazdasági és Jogi Könyvkiadó, Budapest.

- Schumpeter, J.A. (1934): *The Theory of Economic Development*. Oxford University Press, New York.
- Scott, J. (1991): *Social Network Analysis*. Sage, London.
- Sebestyén, T. (2010): Innovation and diversity in a dynamic knowledge network. *KRTI Working papers*, 2010/1.
- Sebestyén, T., Parag, A. (2010): The Dynamics of Link Formation in Patent Innovation Networks. *Perspectives of Innovation, Economics and Business*, 4(1) pp. 21-25.
- Shell, K. (1967): A model of inventive activity and capital accumulation. In: Shell, K. (ed.): *Essays on the optimal theory of growth*. MIT Press, Cambridge, MA., pp 67-85.
- Silverberg, G., Lehnert, D. (1994): Growth fluctuations in an evolutionary model of creative destruction. In: Silverberg, G., Soete, L. (eds.): *The Economics of Growth and Technical Change*, Edward Elgar, UK., pp. 74-108.
- Simon, H.A. (1973): The Structure of Ill-Structured Problems. *Artificial Intelligence*, 4 pp. 181-201.
- Singh J. (2003): Social Networks as Drivers of Knowledge Diffusion. Elérhető: SSRN (Social Science Research Network) DOI: 10.2139/ssrn.431872.
- Smets, F., Wouters, R. (2007): Shocks and Frictions in US Business Cycles: A Bayesian DSGE Approach. *American Economic Review*, 97(3) pp. 586-606.
- Smith, A. (1959): *A nemzetek gazdagsága. E gazdagság természetének és okainak vizsgálata*. Közgazdasági és Jogi Könyvkiadó, Budapest.
- Solow, R.M. (1957): Technical Change and the Aggregate Production Function. *Review of Economics and Statistics*, 39 pp. 312-320.
- Solow, R.M. (1956): A Contribution to the Theory of Economic Growth. *Quarterly Journal of Economics*, 70 pp. 65-94.
- Sorenson, O. (2005): Social Networks, Informal Complexity and Industrial Geography. In: Fornahl, D., Zellner, C., Audretsch, D.B. (eds.): *The Role of Labour Mobility and Informal Networks for Knowledge Flows*. Springer.
- Stoneman P. (2002): *The Economics of Technological Diffusion*. Backwell Publishers, Malden MA.
- Storper, M. (1995): Regional technology coalitions an essential dimension of national technology policy. *Research Policy*, 24(6) pp. 895-911.
- Swan, T.W. (1956): Economic Growth and Capital Accumulation. *Economic Record*, 66 pp. 334-361.
- Ter Wal, A., Boschma, R. (2009): Applying social network analysis in economic geography: framing some key analytic issues. *The Annals of Regional Science*, 43 pp. 739-756.
- Trajtenberg, M. (1990): A Penny for Your Quotes: Patent Citations and the Value of Innovations. *RAND Journal of Economics*, 21(1) pp. 172-187.

- Travers, J., Milgram, S. (1969): An Experimental Study of the Small World Problem. *Sociometry*, 32(4) pp. 425-443.
- Valentinyi, Á. (1995): Endogén növekedésmélelet. Áttekintés. *Közgazdasági Szemle*, XLII. évf., 6. sz. pp. 582-594.
- Varga, A. (2007): From the Geography of Innovation to Development Policy Analysis: The GMR-approach. Working Papers 2007/1, University of Pécs, Department of Economics and Regional Studies.
- Varga, A., Parag, A. (2009): Academic knowledge transfers and the structure of international research networks. In: Varga, A. (ed.): *University knowledge transfers and regional development: Geography, entrepreneurship and policy*. Edward Elgar Publishers, pp. 138-159.
- Varga, A., Járosi, P., Sebestyén, T. (2009): Geographical Macro and Regional Model for EU Policy Impact Analysis of Intangible Assets and Growth. IAREG Working Paper, WP5/20, December, 2009.
- Verspagen, B. (2005): Mapping Technological Trajectories as Patent Citation Networks. A Study on the History of Fuel Cell Research. MERIT Research Memoranda 019.
- Wasserman, S., Faust, K. (1994): *Social Network Analysis – Methods and Application*. Cambridge University press, Cambridge, UK.
- Watts, D.J., Strogatz, S.H. (1998): Collective dynamics of 'small-world' networks. *Nature* 393(6684) pp. 409-410.
- Weterings, A., Boschma, R. (2006): The impacts of geography on the innovative productivity of software firms in the Netherlands. In: Coocke, Piccaluga (eds.): *Regional Development in the Knowledge Economy*, Routledge, UK, pp. 63-83.
- Zucker, L., Darby, M., Armstrong, J. (1994): Intellectual capital and the firm: The technology of geographically localized knowledge spillovers. NBER Working Paper Series, Working Paper no. 4946, NBER, Cambridge

Függelék

Függelék a 3. fejezethez

A keresleti függvény levezetése

Adott a hasznossági függvény és a költségvetési korlát. A megoldandó feladat:

$$U = \left(\sum_{i=1}^N x_i^\sigma \right)^{\frac{1}{\sigma}} \rightarrow \max, \text{ s.t. } I = \sum_{i=1}^N p_i x_i \quad (\text{F.1})$$

A feladat Lagrange függvénye:

$$\Gamma = \left(\sum_{i=1}^N x_i^\sigma \right)^{\frac{1}{\sigma}} + \lambda \left(I - \sum_{i=1}^N p_i x_i \right) \quad (\text{F.2})$$

A Lagrange függvény x_i szerint vett első deriváltja:

$$\frac{\partial \Gamma}{\partial x_i} = \left(\sum_{i=1}^N x_i^\sigma \right)^{\frac{1}{\sigma}-1} x_i^{\sigma-1} - \lambda p_i \quad (\text{F.3})$$

A deriváltat egyenlővé téve nullával kapjuk, hogy

$$\left(\sum_{i=1}^N x_i^\sigma \right)^{\frac{1}{\sigma}-1} x_i^{\sigma-1} = \lambda p_i \quad (\text{F.4})$$

Az így kapott N egyenletből λ -kat kiküszöbölve azt kapjuk, hogy

$$\frac{x_i}{x_j} = \left(\frac{p_i}{p_j} \right)^{\frac{1}{\sigma-1}} \quad (\text{F.5})$$

bármely (i, j) párra (értelemszerűen $i = j$ esetén egyszerű azonosságot kapunk). Ha élünk a $j = 1$ helyettesítéssel, akkor a fenti összefüggést felírhatjuk, mint

$$x_i = \left(\frac{p_i}{p_1} \right)^{\frac{1}{\sigma-1}} x_1 \quad (\text{F.6})$$

azaz bármely termék keresletét kifejezhetjük egy másik termék kereslete és az árányok függvényében. A fenti összefüggéseket a költségvetési korlátba helyettesítve:

$$I = \sum_{i=1}^N p_i \left(\frac{p_i}{p_1} \right)^{\frac{1}{\sigma-1}} x_1 \quad (\text{F.7})$$

adódik, amelyet kifejezve x_1 -re kapjuk, hogy

$$x_1 = \frac{I}{\sum_{i=1}^N p_i \left(\frac{p_i}{p_1} \right)^{\frac{1}{\sigma-1}}} \quad (\text{F.8})$$

Vezessük be az $\varepsilon = 1/(1 - \sigma)$ jelölést. Így a fenti összefüggést egyszerűsíthetjük:

$$x_1 = p_1^{-\varepsilon} \frac{I}{\sum_{i=1}^N p_i^{1-\varepsilon}} \quad (\text{F.9})$$

Amennyiben a fenti műveletsort tetszőleges j -re elvégezzük, könnyen belátható, hogy a j termék iránti kereslet:

$$x_j = p_j^{-\varepsilon} \frac{I}{\sum_{i=1}^N p_i^{1-\varepsilon}} \quad (\text{F.10})$$

Az előző levezetéshez természetesen szükséges annak a vizsgálata, hogy az (F.10) megoldások valóban hasznosságmaximumot jelentenek-e, vagyis az optimalizáció másodrendű feltételeit is szükséges vizsgálnunk. Ismert, hogy egy függvény stacionárius pontja globális maximumhely a Z értelmezési tartományon, amennyiben a függvény Z -n konkáv. Többek között Carter (2001) azonban megmutatja, hogy az itt használt egyszerű CES hasznossági függvény $\sigma \leq 1$ esetén valóban konkáv, amely feltétel azonban egybevág az általunk használt feltevessel. Így viszont a releváns értelmezési tartományon az (F.10) által meghatározott szélsőérték hely globális maximumhely, vagyis hasznosságmaximum.

■

A profitmaximum meghatározása

Adott az alábbi profitfüggvény:

$$\pi_i = p_i^{1-\varepsilon} \frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} - w K_i^{-1/\alpha} p_i^{-\varepsilon/\alpha} \left(\frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} \right)^{\frac{1}{\alpha}} \quad (\text{F.11})$$

A fenti profitfüggvény p_i szerinti deriváltja, figyelembe véve, hogy a $\sum_j p_j^{1-\varepsilon}$ összeg megfelelő deriváltja feltevésünk szerint zérus:

$$\frac{\partial \pi_i}{\partial p_i} = (1 - \varepsilon) p_i^{-\varepsilon} \frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} + \frac{\varepsilon}{\alpha} w K_i^{-1/\alpha} p_i^{-\varepsilon/\alpha-1} \left(\frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} \right)^{\frac{1}{\alpha}} \quad (\text{F.12})$$

A fenti kifejezést nullára rendezve és p_i -t kifejezve adódik, hogy

$$p_i = w^\varphi K_i^{-\varphi/\alpha} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^\varphi \left(\frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} \right)^{\frac{(1-\alpha)\varphi}{\alpha}} \quad (\text{F.13})$$

ahol $\varphi = (\alpha - \alpha\sigma)/(1 - \alpha\sigma)$. A profitmaximum másodrendű feltétele, hogy az (F.13) összefüggés által adott stacionárius pont a π_i függvény maximuma legyen. Mivel az (F.11) profitfüggvény konvex és konkáv szakaszokkal is rendelkezhet, így e függvény konvexitásának/konkavitásának vizsgálatával a szélsőérték-hely jellege nem állapítható meg. Mivel azonban a profitfüggvény számunkra releváns értelmezési tartományán ($p_i > 0$) az (F.13) stacionárius pont egyértelműen létezik, elegendő csupán e stacionárius pont környezetében vizsgálni a profitfüggvény másodrendű tulajdonságait. Ehhez alkalmazzuk a profitfüggvény alábbi, egyszerűbb formáját:

$$\pi(p) = ap^{1-\varepsilon} - bp^{-\varepsilon/\alpha} \quad (\text{F.14})$$

A profitfüggvény első deriváltja az (F.12) összefüggésnek megfelelően adható meg, ezek alapján pedig a szélsőérték hely az alábbi formát ölti:

$$p = \left(\frac{b}{a} \right)^\varphi \left(\frac{\varepsilon}{\alpha(\varepsilon - 1)} \right)^\varphi \quad (\text{F.15})$$

A profitfüggvény második deriváltja:

$$\frac{\partial^2 \pi}{\partial p^2} = (\varepsilon - 1)\varepsilon ap^{-(\varepsilon+1)} - b \frac{\varepsilon}{\alpha} \left(\frac{\varepsilon}{\alpha} + 1 \right) p^{-\left(\frac{\varepsilon}{\alpha}+2\right)} \quad (\text{F.16})$$

Az (F.15) szélsőérték hely akkor maximum, ha a $\pi(p)$ függvény második deriváltja negatív az adott pontban. Az (F.16) összefüggést egyszerűsítve és a maximumhely feltételét alkalmazva azt kapjuk, hogy

$$\frac{\varepsilon - 1}{\varepsilon + \alpha} \alpha^2 \frac{a}{b} < p^{-1/\varphi} \quad (\text{F.17})$$

amibe az (F.15) képletből behelyettesítve p értékét a stacionárius pontban egyszerűsítés után adódik a következő egyszerű összefüggés:

$$\frac{1}{\varepsilon + \alpha} \alpha < \frac{1}{\varepsilon} \quad (\text{F.18})$$

Figyelembe véve az α paraméterre tett $0 < \alpha < 1$ kikötést, könnyen belátható, hogy a fenti feltétel mindig teljesül. Ez pedig azt jelenti, hogy a korábban meghatározott optimális árszint valóban maximális profitot eredményez.

■

Az egyensúlyi bérszint meghatározása homogén szereplők esetén

Tegyük fel, hogy

$$K_i = \hat{K}, i = 1, 2, \dots, N \quad (\text{F.19})$$

Ekkor a vállalatok profirmaximalizáló ára:

$$p_i = w^\varphi \hat{K}_i^{-\varphi/\alpha} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^\varphi \left(\frac{I}{\sum_{j=1}^N p_j^{1-\varepsilon}} \right)^{\frac{1-\alpha}{\alpha} \varphi} \quad (\text{F.20})$$

Mint ahogy tetszőleges \mathbf{p} vektor esetén az utolsó zárójelben lévő $\sum_j p_j^{1-\varepsilon}$ kifejezés minden vállalat számára azonos, így az egyes vállalatok által megállapított ár is egyforma lesz. Ennek megfelelően a fenti képlet az alábbi formában írható fel:

$$\hat{p} = w^\varphi \hat{K}^{-\frac{\varphi}{\alpha}} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^\varphi \left(\frac{I}{N \hat{p}^{1-\varepsilon}} \right)^{\frac{1-\alpha}{\alpha} \varphi} \quad (\text{F.21})$$

Amiből \hat{p} -t kifejezve kapjuk, hogy

$$\hat{p} = w^{\frac{\varphi}{\gamma}} \hat{K}^{-\frac{\varphi}{\alpha\gamma}} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^{\frac{\varphi}{\gamma}} \left(\frac{I}{N} \right)^{\frac{1-\alpha}{\alpha} \frac{\varphi}{\gamma}} \quad (\text{F.22})$$

Ahol $\gamma = 1 + \varphi(1 - \varepsilon)(1 - \alpha)/\alpha$. A keresleti függvény segítségével az output most már könnyen kifejezhető:

$$\hat{y} = w^{-\frac{\varphi}{\gamma}} \hat{K}^{\frac{\varphi}{\alpha\gamma}} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^{-\frac{\varphi}{\gamma}} \left(\frac{I}{N} \right)^{1 - \frac{1-\alpha}{\alpha} \frac{\varphi}{\gamma}} \quad (\text{F.23})$$

A kibocsátásból adódik a munkafelhasználás:

$$\hat{L} = w^{-\frac{\varphi}{\gamma\alpha}} \hat{K}^{\frac{\varphi}{\alpha^2\gamma} - \frac{1}{\alpha}} \left[\frac{\varepsilon}{(\varepsilon - 1)\alpha} \right]^{-\frac{\varphi}{\gamma\alpha}} \left(\frac{I}{N} \right)^{\left(1 - \frac{1-\alpha}{\alpha} \frac{\varphi}{\gamma}\right) \frac{1}{\alpha}} \quad (\text{F.24})$$

A munkapiaci egyensúly feltétele, hogy az összes munkafelhasználás megegyezzen a munkakínálattal. Mivel most a munkafelhasználás vállalatonként azonos, így ez a feltétel egyszerűen:

$$N\hat{L} = \bar{L} \quad (\text{F.25})$$

Behelyettesítve \hat{L} -re az imént kapott összefüggést és w -re átrendezve kapjuk, hogy:

$$\hat{w} = \alpha \frac{\varepsilon - 1}{\varepsilon} \hat{K}^\eta \bar{I}^{1-\eta} N^\eta \bar{L}^{\eta\alpha-1} \quad (\text{F.26})$$

Ahol $\eta = 1/\alpha - \gamma/\varphi$. Könnyen megmutatható azonban, hogy $\eta = 0$ α és ε bármely értéke mellett, így a bérre kapott kifejezés a következő formára egyszerűsödik:

$$\hat{w} = \alpha \frac{\varepsilon - 1}{\varepsilon} \frac{\bar{I}}{\bar{L}} \quad (\text{F.27})$$

■

Függelék az 5. fejezethez

	<i>Teljes gazdaság</i>		<i>High-tech szektor</i>	
	<i>Régió</i>	<i>TFP</i>	<i>Régió</i>	<i>TFP</i>
1.	London	98	Bretagne	600
2.	Hamburg	92	London	529
3.	Île de France	83	Provence-Alpes-Côte d'Azur	500
4.	Bremen	81	Basse-Normandie	464
5.	North Eastern Scotland	73	Eastern Scotland	434
6.	Oberbayern	73	Bremen	395
7.	Berks., Bucks and Oxfords.	73	Northern Ireland	394
8.	Darmstadt	72	East Anglia	380
9.	Düsseldorf	63	Gloucesters., Wilts., Bristol	372
10.	Cheshire	63	Midi-Pyrénées	342
11.	Stuttgart	61	Hampshire and Isle of Wight	306
12.	Mittelfranken	61	Oberbayern	303
13.	Bedfords., Hertfords.	60	Surrey, E.,W. Sussex	297
14.	Gloucesters., Wilts., Bristol	60	Sachsen-Anhalt	293
15.	Karlsruhe	60	Brandenburg	291
16.	West Midlands	59	Dorset and Somerset	288
17.	Köln	59	Hamburg	283
18.	Surrey, E.,W. Sussex	58	Hannover	282
19.	East Wales	57	Île de France	277
20.	Eastern Scotland	56	Oberpfalz	273
21.	Prov.-Alpes-Côte d'Azur	56	Highlands and Islands	273

	<i>Teljes gazdaság</i>		<i>High-tech szektor</i>	
	<i>Régió</i>	<i>TFP</i>	<i>Régió</i>	<i>TFP</i>
22.	Greater Manchester	55	Mecklenburg-Vorpommern	270
23.	Saarland	55	East Wales	267
24.	West Yorkshire	55	Berlin	258
25.	Rhône-Alpes	55	Mittelfranken	242
26.	Braunschweig	55	Dresden	236
27.	Leicesters., Rutl., Northants	55	South Western Scotland	236
28.	South Western Scotland	55	Rhône-Alpes	233
29.	Oberpfalz	54	South Yorkshire	229
30.	Schwaben	54	Languedoc-Roussillon	213
31.	Hannover	54	North Yorkshire	211
32.	Arnsberg	54	Devon	209
33.	Kassel	54	West Yorkshire	202
34.	Tübingen	54	Greater Manchester	201
35.	Unterfranken	53	Berks., Bucks., Oxfords.	194
36.	Hampshire and Isle of Wight	53	Köln	193
37.	Berlin	53	Braunschweig	191
38.	Northumberland, Tyne and Wear	53	Essex	188
39.	Oberfranken	52	Herefords., Worcesters., Warks	186
40.	Champagne-Ardenne	52	Detmold	180
41.	Derbyshire and Nottinghamshire	52	Oberfranken	178
42.	Detmold	52	Niederbayern	178
43.	Haute-Normandie	52	West Midlands	170
44.	Aquitaine	52	Thüringen	161
45.	Northern Ireland	51	Kent	161
46.	Alsace	51	North Eastern Scotland	159
47.	Rheinhessen-Pfalz	51	Derbyshire and Nottinghamshire	157
48.	Freiburg	51	Lüneburg	157
49.	Niederbayern	50	Leipzig	155
50.	East Anglia	50	Alsace	151
51.	North Yorkshire	50	Nord - Pas-de-Calais	151
52.	Nord - Pas-de-Calais	50	Lincolnshire	147
53.	East Yorksh., Northern Lincolnsh.	49	Bourgogne	144
54.	Weser-Ems	49	West Wales and The Valleys	142
55.	Herefordsh., Worcestersh., Warks	49	Stuttgart	135
56.	Gießen	49	Darmstadt	134
57.	Languedoc-Roussillon	49	Pays de la Loire	134
58.	Schleswig-Holstein	49	Bedfordshire, Hertfordshire	134
59.	Pays de la Loire	49	Aquitaine	128
60.	Midi-Pyrénées	48	Düsseldorf	126
61.	Lancashire	48	Leicesters., Rutl., Northants	124
62.	Centre	48	Karlsruhe	122
63.	Bourgogne	48	Arnsberg	116
64.	Münster	48	Northumberland, Tyne and Wear	116
65.	Franche-Comté	48	Auvergne	115

	<i>Teljes gazdaság</i>		<i>High-tech szektor</i>	
	<i>Régió</i>	<i>TFP</i>	<i>Régió</i>	<i>TFP</i>
66.	Bretagne	48	Schwaben	115
67.	Lorraine	47	Münster	113
68.	South Yorkshire	47	Centre	110
69.	Essex	47	Gießen	110
70.	Kent	47	Tübingen	109
71.	Merseyside	47	Schleswig-Holstein	109
72.	Picardie	46	Poitou-Charentes	105
73.	Auvergne	46	Weser-Ems	105
74.	Tees Valley and Durham	46	Cheshire	103
75.	Poitou-Charentes	46	Cornwall, Isles of Scilly	101
76.	Basse-Normandie	46	Trier	100
77.	Dorset and Somerset	46	Kassel	98
78.	Koblenz	45	Tees Valley and Durham	97
79.	Trier	45	Chemnitz	94
80.	Limousin	45	Rheinhessen-Pfalz	91
81.	Leipzig	44	Merseyside	84
82.	Cumbria	44	Shropshire and Staffordshire	84
83.	Shropshire and Staffordshire	44	Freiburg	83
84.	Guadeloupe (FR)	44	Saarland	82
85.	Devon	44	Unterfranken	82
86.	Dresden	43	Lancashire	69
87.	Lincolnshire	43	Lorraine	68
88.	Mecklenburg-Vorpommern	41	Champagne-Ardenne	62
89.	West Wales and The Valleys	41	Cumbria	62
90.	Highlands and Islands	41	Picardie	62
91.	Lüneburg	40	Koblenz	59
92.	Brandenburg	40	Haute-Normandie	51
93.	Thüringen	40	Franche-Comté	50
94.	Chemnitz	39	Limousin	37
95.	Cornwall and Isles of Scilly	37	Guadeloupe (FR)	N.a.
96.	Sachsen-Anhalt	37	East Yorksh., Northern Lincolnsh.	N.a.

F1 – Régiók teljes listája, becsült TFP értékek szerint, a teljes gazdaságra és a high-tech szektorra vonatkozóan

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	4,949	0,258	19,158	***
HTPAT	0,463	0,030	15,394	***
HTPAT_W_v1	-0,084	0,023	-3,712	***
Mean depend var	5,470	S.D. depend var	0,666	
Sum squared resid	67,282	S.E. of regression	0,492	
Log-likelihood	-197,68	Akaike criterion	401,356	
Schwarz criterion	412,260	Hannan-Quinn	405,729	

F2 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, egyszerű összeggel, kooperációs hálózati súlyokkal és súlyozott kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	4,865	0,239	20,322	***
HTPAT	0,463	0,030	15,393	***
HTPAT_W_v2	-0,080	0,022	-3,691	***
Mean depend var	5,470	S.D. depend var	0,666	
Sum squared resid	67,688	S.E. of regression	0,493	
Log-likelihood	-198,52	Akaike criterion	403,038	
Schwarz criterion	413,943	Hannan-Quinn	407,412	

F3 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, egyszerű összeggel, szabadalomszámon alapuló hálózati súlyokkal és súlyozott kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	4,615	0,323	14,301	***
HTPAT	0,438	0,030	14,815	***
HTPAT_U_v1	-0,063	0,035	-1,8252	*
Mean depend var	5,470	S.D. depend var	0,666	
Sum squared resid	73,389	S.E. of regression	0,514	
Log-likelihood	-209,84	Akaike criterion	425,679	
Schwarz criterion	436,584	Hannan-Quinn	430,053	

F4 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, egyszerű összeggel, kooperációs hálózati súlyokkal és bináris kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	4,615	0,323	14,301	***
HTPAT	0,438	0,030	14,815	***
HTPAT_U_v2	-0,063	0,0346	-1,825	*
Mean depend var	5,470	S.D. depend var	0,666	
Sum squared resid	73,389	S.E. of regression	0,514	
Log-likelihood	-209,84	Akaike criterion	425,679	
Schwarz criterion	436,584	Hannan-Quinn	430,053	

F5 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, egyszerű összeggel, szabadalomszámon alapuló hálózati súlyokkal és bináris kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	4,912	0,270	18,161	***
HTPAT	0,464	0,031	15,164	***
HTPAT_W_v1	-0,086	0,025	-3,394	***
Mean depend var	5,470	S.D. depend var	0,666	
Sum squared resid	68,591	S.E. of regression	0,497	
Log-likelihood	-200,38	Akaike criterion	406,751	
Schwarz criterion	417,655	Hannan-Quinn	411,125	

F6 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, gördülő összeggel, kooperációs hálózati súlyokkal és súlyozott kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	4,836	0,249	19,391	***
HTPAT	0,464	0,031	15,180	***
HTPAT_W_v2	-0,082	0,024	-3,412	***
Mean depend var	5,470	S.D. depend var	0,666	
Sum squared resid	68,810	S.E. of regression	0,498	
Log-likelihood	-200,82	Akaike criterion	407,642	
Schwarz criterion	418,547	Hannan-Quinn	412,016	

F7 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, gördülő összeggel, szabadalomszámon alapuló hálózati súlyokkal és súlyozott kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	4,464	0,356	12,528	***
HTPAT	0,436	0,030	14,571	***
HTPAT_U_v1	-0,050	0,041	-1,219	
Mean depend var	5,470	S.D. depend var	0,666	
Sum squared resid	75,590	S.E. of regression	0,521	
Log-likelihood	-213,98	Akaike criterion	433,956	
Schwarz criterion	444,860	Hannan-Quinn	438,329	

F8 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, gördülő összeggel, kooperációs hálózati súlyokkal és bináris kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	4,464	0,356	12,528	***
HTPAT	0,436	0,030	14,571	***
HTPAT_U_v2	-0,050	0,041	-1,220	
Mean depend var	5,470	S.D. depend var	0,666	
Sum squared resid	75,590	S.E. of regression	0,521	
Log-likelihood	-213,98	Akaike criterion	433,956	
Schwarz criterion	444,860	Hannan-Quinn	438,329	

F9 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, gördülő összeggel, szabadalomszámon alapuló hálózati súlyokkal és bináris kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	2,926	0,066	44,453	***
HTPAT	0,002	0,010	0,185	
HTPAT_W_v1	0,010	0,003	3,086	***
Mean depend var	3,071	S.D. depend var	0,159	
Sum squared resid	6,862	S.E. of regression	0,157	
Log-likelihood	121,918	Akaike criterion	-237,84	
Schwarz criterion	-226,93	Hannan-Quinn	-233,46	

F10 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, egyszerű összeggel, kooperációs hálózati súlyokkal és súlyozott kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	2,940	0,064	45,787	***
HTPAT	0,002	0,010	0,197	
HTPAT_W_v2	0,009	0,003	2,970	***
Mean depend var	3,071	S.D. depend var	0,159	
Sum squared resid	6,863	S.E. of regression	0,157	
Log-likelihood	121,906	Akaike criterion	-237,81	
Schwarz criterion	-226,91	Hannan-Quinn	-233,44	

F11 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, egyszerű összeggel, szabadalom-számon alapuló hálózati súlyokkal és súlyozott kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	2,935	0,069	42,133	***
HTPAT	0,004	0,010	0,446	
HTPAT_U_v1	0,010	0,004	2,422	**
Mean depend var	3,071	S.D. depend var	0,159	
Sum squared resid	6,893	S.E. of regression	0,157	
Log-likelihood	121,292	Akaike criterion	-236,58	
Schwarz criterion	-225,68	Hannan-Quinn	-232,21	

F12 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, egyszerű összeggel, kooperációs hálózati súlyokkal és bináris kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	2,935	0,070	42,133	***
HTPAT	0,004	0,010	0,446	
HTPAT_U_v2	0,010	0,004	2,422	**
Mean depend var	3,071	S.D. depend var	0,159	
Sum squared resid	6,893	S.E. of regression	0,157	
Log-likelihood	121,292	Akaike criterion	-236,58	
Schwarz criterion	-225,68	Hannan-Quinn	-232,21	

F13 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, egyszerű összeggel, szabadalom-számon alapuló hálózati súlyokkal és bináris kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	2,888	0,068	42,689	***
HTPAT	0,001	0,010	0,151	
HTPAT_W_v1	0,014	0,004	3,800	***
Mean depend var	3,071	S.D. depend var	0,159	
Sum squared resid	6,791	S.E. of regression	0,156	
Log-likelihood	123,379	Akaike criterion	-240,76	
Schwarz criterion	-229,85	Hannan-Quinn	-236,38	

F14 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság szektor adatai alapján, gördülő összeggel, kooperációs hálózati súlyokkal és súlyozott kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	2,905	0,066	44,178	***
HTPAT	0,002	0,010	0,155	
HTPAT_W_v2	0,013	0,003	3,673	***
Mean depend var	3,071	S.D. depend var	0,159	
Sum squared resid	6,805	S.E. of regression	0,156	
Log-likelihood	123,092	Akaike criterion	-240,18	
Schwarz criterion	-229,28	Hannan-Quinn	-235,81	

F15 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, gördülő összeggel, szabadalom-számon alapuló hálózati súlyokkal és súlyozott kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	2,876	0,074	38,648	***
HTPAT	0,005	0,010	0,468	
HTPAT_U_v1	0,016	0,005	3,248	***
Mean depend var	3,071	S.D. depend var	0,159	
Sum squared resid	6,836	S.E. of regression	0,157	
Log-likelihood	122,450	Akaike criterion	-238,9	
Schwarz criterion	-227,1	Hannan-Quinn	-234,53	

F16 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, gördülő összeggel, kooperációs hálózati súlyokkal és bináris kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	2,876	0,074	38,648	***
HTPAT	0,005	0,010	0,468	
HTPAT_U_v2	0,016	0,005	3,248	***
Mean depend var	3,071	S.D. depend var	0,159	
Sum squared resid	6,836	S.E. of regression	0,157	
Log-likelihood	122,450	Akaike criterion	-238,9	
Schwarz criterion	-228,0	Hannan-Quinn	-234,53	

F17 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, gördülő összeggel, szabadalom-számon alapuló hálózati súlyokkal és bináris kapcsolati mátrixszal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	5,616	0,081	69,043	***
RELINK_v1	-0,010	0,049	-2,019	**
Mean depend var	5,543	S.D. depend var	0,664	
Sum squared resid	107,567	S.E. of regression	0,641	
Log-likelihood	-255,62	Akaike criterion	515,230	
Schwarz criterion	522,374	Hannan-Quinn	518,101	

F18 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó változóval, kooperációs hálózati súlyokkal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	5,554	0,071	78,650	***
RELINK_v2	-0,052	0,039	-1,338	
Mean depend var	5,543	S.D. depend var	0,664	
Sum squared resid	110,354	S.E. of regression	0,649	
Log-likelihood	-258,98	Akaike criterion	521,956	
Schwarz criterion	529,100	Hannan-Quinn	524,827	

F19 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó változóval, szabadalomszámon alapuló hálózati súlyokkal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	5,387	0,087	61,963	***
I.SHARE_v1	-0,3278	0,164	-1,998	**
Mean depend var	5,514	S.D. depend var	0,670	
Sum squared resid	115,818	S.E. of regression	0,644	
Log-likelihood	-273,72	Akaike criterion	551,431	
Schwarz criterion	558,700	Hannan-Quinn	554,347	

F20 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó változóval, kooperációs hálózati súlyokkal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	5,420	0,084	64,543	***
I.SHARE_v2	-0,181	0,115	-1,574	
Mean depend var	5,514	S.D. depend var	0,670	
Sum squared resid	117,900	S.E. of regression	0,650	
Log-likelihood	-276,21	Akaike criterion	556,417	
Schwarz criterion	563,687	Hannan-Quinn	559,333	

F21 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó változóval, szabadalomszámon alapuló hálózati súlyokkal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	-0,097	0,133	-0,732	
HTPAT	0,073	0,016	4,670	***
X_v1	0,467	0,061	7,646	***
Mean depend var	0,950	S.D. depend var	0,305	
Sum squared resid	26,653	S.E. of regression	0,320	
Log-likelihood	-72,14	Akaike criterion	150,285	
Schwarz criterion	161,002	Hannan-Quinn	154,592	

F22 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó- és eredményváltozóval, egyszerű összeggel, kooperációs hálózati súlyokkal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	0,285	0,123	2,319	**
HTPAT	0,103	0,018	5,800	***
X_v2	0,205	0,049	4,198	***
Mean depend var	0,972	S.D. depend var	0,330	
Sum squared resid	41,500	S.E. of regression	0,399	
Log-likelihood	-130,37	Akaike criterion	266,736	
Schwarz criterion	277,452	Hannan-Quinn	271,042	

F23 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó- és eredményváltozóval, egyszerű összeggel, szabadalomszámon alapuló hálózati súlyokkal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	-0,436	0,186	-2,342	**
HTPAT	0,163	0,024	6,680	***
X_v1	0,612	0,068	9,052	***
Mean depend var	1,185	S.D. depend var	0,683	
Sum squared resid	128,286	S.E. of regression	0,701	
Log-likelihood	-278,78	Akaike criterion	563,556	
Schwarz criterion	574,272	Hannan-Quinn	567,862	

F24 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó- és eredményváltozóval, gördülő összeggel, kooperációs hálózati súlyokkal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	0,149	0,189	0,791	
HTPAT	0,036	0,028	1,288	
X_v2	0,488	0,065	7,549	***
Mean depend var	1,199	S.D. depend var	0,518	
Sum squared resid	55,448	S.E. of regression	0,463	
Log-likelihood	-168,19	Akaike criterion	342,379	
Schwarz criterion	353,072	Hannan-Quinn	346,677	

F25 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó- és eredményváltozóval, gördülő összeggel, szabadalomszámon alapuló hálózati súlyokkal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	0,188	0,342	0,550	
HTPAT	-0,094	0,076	-1,225	
X_v1	0,103	0,057	1,801	*
Mean depend var	0,080	S.D. depend var	0,929	
Sum squared resid	65,455	S.E. of regression	0,905	
R-squared	0,076	Adj. R-squared	0,053	
F(2, 80)	3,279	P-value(F)	0,043	
Log-likelihood	-107,92	Akaike criterion	221,834	
Schwarz criterion	229,090	Hannan-Quinn	224,749	

F26 – OLS-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, növekedési rátákkal, korrigált magyarázó változókkal, kooperációs hálózati súlyokkal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	-0,186	0,155	-1,201	
X_v1	0,123	0,055	2,242	**
Mean depend var	0,080	S.D. depend var	0,929	
Sum squared resid	66,682	S.E. of regression	0,907	
R-squared	0,058	Adj. R-squared	0,047	
F(2, 80)	5,029	P-value(F)	0,028	
Log-likelihood	-108,69	Akaike criterion	221,375	
Schwarz criterion	226,213	Hannan-Quinn	223,318	

F27 – OLS-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, növekedési rátákkal, korrigált magyarázó változókkal, kooperációs hálózati súlyokkal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	0,175	0,350	0,500	
HTPAT	-0,093	0,077	-1,218	
X_v2	0,107	0,061	1,757	*
Mean depend var	0,080	S.D. depend var	0,929	
Sum squared resid	65,579	S.E. of regression	0,905	
R-squared	0,074	Adj. R-squared	0,051	
F(2, 80)	3,198	P-value(F)	0,046	
Log-likelihood	-108,0	Akaike criterion	221,991	
Schwarz criterion	229,247	Hannan-Quinn	224,906	

F28 – OLS-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, növekedési rátákkal, korrigált magyarázó változókkal, szabadalomszámon alapuló hálózati súlyokkal

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	-0,203	0,162	-1,252	
X_v2	0,129	0,058	2,210	**
Mean depend var	0,080	S.D. depend var	0,929	
Sum squared resid	66,794	S.E. of regression	0,908	
R-squared	0,057	Adj. R-squared	0,045	
F(2, 80)	4,884	P-value(F)	0,030	
Log-likelihood	-108,76	Akaike criterion	221,514	
Schwarz criterion	226,352	Hannan-Quinn	223,458	

F29 – OLS-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, növekedési rátákkal, korrigált magyarázó változókkal, szabadalomszámra alapuló hálózati súlyokkal

Függelék a 6. fejezethez

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,750	0,098	99,050	***
log_CLS	-0,162	0,030	-5,435	***
Mean depend var	9,761	S.D. depend var	0,455	
Sum squared resid	90,798	S.E. of regression	0,467	
Log-likelihood	-273,85	Akaike criterion	551,698	
Schwarz criterion	559,764	Hannan-Quinn	554,887	

F30 – Panel-regressziós eredmények a reálkibocsátásra, késleltetés nélkül, független változó: relatív klaszterezettség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,755	0,098	99,833	***
log_CLS	-0,152	0,031	-4,905	***
Mean depend var	9,774	S.D. depend var	0,451	
Sum squared resid	85,636	S.E. of regression	0,466	
Log-likelihood	-258,7	Akaike criterion	521,401	
Schwarz criterion	529,364	Hannan-Quinn	524,556	

F31 – Panel-regressziós eredmények a reálkibocsátásra, egy éves késleltetéssel, független változó: relatív klaszterezettség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,761	0,101	96,760	***
log_CLS	-0,146	0,031	-4,657	***
Mean depend var	9,789	S.D. depend var	0,441	
Sum squared resid	80,238	S.E. of regression	0,457	
Log-likelihood	-242,84	Akaike criterion	452,110	
Schwarz criterion	497,530	Hannan-Quinn	455,187	

F32 – Panel-regressziós eredmények a reálkibocsátásra, két éves késleltetéssel, független változó: relatív klaszterezettség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,811	0,103	95,668	***
log_CLS	-0,169	0,032	-5,352	***
Mean depend var	9,805	S.D. depend var	0,441	
Sum squared resid	73,554	S.E. of regression	0,457	
Log-likelihood	-224,06	Akaike criterion	452,110	
Schwarz criterion	459,843	Hannan-Quinn	455,187	

F33 – Panel-regressziós eredmények a reálkibocsátásra, három éves késleltetéssel, független változó: relatív klaszterezettség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,843	0,102	96,564	***
log_CLS	-0,204	0,032	-6,390	***
Mean depend var	9,818	S.D. depend var	0,437	
Sum squared resid	70,322	S.E. of regression	0,460	
Log-likelihood	-213,59	Akaike criterion	431,178	
Schwarz criterion	438,794	Hannan-Quinn	434,215	

F34 – Panel-regressziós eredmények a reálkibocsátásra, négy éves késleltetéssel, független változó: relatív klaszterezettség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,843	0,102	96,564	***
log_CLS	-0,204	0,032	-6,390	***
Mean depend var	9,818	S.D. depend var	0,437	
Sum squared resid	70,322	S.E. of regression	0,460	
Log-likelihood	-213,59	Akaike criterion	431,178	
Schwarz criterion	438,794	Hannan-Quinn	434,215	

F35 – Panel-regressziós eredmények a reálkibocsátásra, öt éves késleltetéssel, független változó: relatív klaszterezettség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,632	0,088	109,195	***
log_PATH	-0,200	0,0923	-2,168	**
Mean depend var	9,696	S.D. depend var	0,487	
Sum squared resid	114,505	S.E. of regression	0,496	
Log-likelihood	-334,19	Akaike criterion	672,387	
Schwarz criterion	680,676	Hannan-Quinn	675,649	

F36 – Panel-regressziós eredmények a reálkibocsátásra, késleltetés nélkül, független változó: relatív elérési úthossz

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,642	0,091	105,691	***
log_PATH	-0,130	0,092	-1,420	
Mean depend var	9,705	S.D. depend var	0,488	
Sum squared resid	108,702	S.E. of regression	0,495	
Log-likelihood	-317,82	Akaike criterion	639,645	
Schwarz criterion	647,841	Hannan-Quinn	642,877	

F37 – Panel-regressziós eredmények a reálkibocsátásra, egy éves késleltetéssel, független változó: relatív elérési úthossz

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,653	0,092	104,558	***
log_PATH	-0,112	0,090	-1,254	
Mean depend var	9,714	S.D. depend var	0,488	
Sum squared resid	103,380	S.E. of regression	0,494	
Log-likelihood	-302,43	Akaike criterion	608,861	
Schwarz criterion	616,961	Hannan-Quinn	612,061	

F38 – Panel-regressziós eredmények a reálkibocsátásra, két éves késleltetéssel, független változó: relatív elérési úthossz

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,665	0,094	102,967	***
log_PATH	-0,107	0,088	-1,212	
Mean depend var	9,726	S.D. depend var	0,487	
Sum squared resid	97,693	S.E. of regression	0,493	
Log-likelihood	-286,29	Akaike criterion	576,572	
Schwarz criterion	584,569	Hannan-Quinn	579,738	

F39 – Panel-regressziós eredmények a reálkibocsátásra, három éves késleltetéssel, független változó: relatív elérési úthossz

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,676	0,096	101,174	***
log_PATH	-0,074	0,087	-0,842	
Mean depend var	9,738	S.D. depend var	0,487	
Sum squared resid	92,223	S.E. of regression	0,492	
Log-likelihood	-270,58	Akaike criterion	545,168	
Schwarz criterion	553,059	Hannan-Quinn	548,298	

F40 – Panel-regressziós eredmények a reálkibocsátásra, négy éves késleltetéssel, független változó: relatív elérési úthossz

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,687	0,096	100,444	***
log_PATH	-0,007	0,084	-0,088	
Mean depend var	9,752	S.D. depend var	0,486	
Sum squared resid	86,175	S.E. of regression	0,490	
Log-likelihood	-253,47	Akaike criterion	510,935	
Schwarz criterion	518,707	Hannan-Quinn	514,025	

F41 – Panel-regressziós eredmények a reálkibocsátásra, öt éves késleltetéssel, független változó: relatív elérési úthossz

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,729	0,096	101,030	***
log_SCALE	0,005	0,011	0,416	
Mean depend var	9,785	S.D. depend var	0,443	
Sum squared resid	66,982	S.E. of regression	0,447	
Log-likelihood	-205,83	Akaike criterion	415,665	
Schwarz criterion	423,299	Hannan-Quinn	418,708	

F42 – Panel-regressziós eredmények a reálkibocsátásra, késleltetés nélkül, független változó: súlyozatlan hálózattól számolt relatív skálafüggetlenség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,737	0,097	100,317	***
log_SCALE	0,005	0,011	0,425	
Mean depend var	9,797	S.D. depend var	0,440	
Sum squared resid	62,849	S.E. of regression	0,445	
Log-likelihood	-193,54	Akaike criterion	391,082	
Schwarz criterion	398,613	Hannan-Quinn	394,090	

F43 – Panel-regressziós eredmények a reálkibocsátásra, egy éves késleltetéssel, független változó: súlyozatlan hálózattól számolt relatív skálafüggetlenség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,748	0,097	100,228	***
log_SCALE	0,003	0,011	0,255	
Mean depend var	9,813	S.D. depend var	0,436	
Sum squared resid	58,222	S.E. of regression	0,441	
Log-likelihood	-179,75	Akaike criterion	363,508	
Schwarz criterion	370,915	Hannan-Quinn	366,472	

F44 – Panel-regressziós eredmények a reálkibocsátásra, két éves késleltetéssel, független változó: súlyozatlan hálózattól számolt relatív skálafüggetlenség

	Coefficient	St. hiba	t-stat.	
const	9,763	0,097	101,145	***
log_SCALE	-0,004	0,012	-0,332	
Mean depend var	9,831	S.D. depend var	0,432	
Sum squared resid	53,459	S.E. of regression	0,437	
Log-likelihood	-165,57	Akaike criterion	335,140	
Schwarz criterion	342,417	Hannan-Quinn	338,058	

F45 – Panel-regressziós eredmények a reálkibocsátásra, három éves késleltetéssel, független változó: súlyozatlan hálózathálóból számolt relatív skálafüggetlenség

	Coefficient	St. hiba	t-stat.	
const	9,775	0,095	102,399	***
log_SCALE	-0,004	0,012	-0,329	
Mean depend var	9,845	S.D. depend var	0,432	
Sum squared resid	50,086	S.E. of regression	0,437	
Log-likelihood	-155,1	Akaike criterion	314,197	
Schwarz criterion	321,342	Hannan-Quinn	317,068	

F46 – Panel-regressziós eredmények a reálkibocsátásra, négy éves késleltetéssel, független változó: súlyozatlan hálózathálóból számolt relatív skálafüggetlenség

	Coefficient	St. hiba	t-stat.	
const	9,788	0,093	105,240	***
log_SCALE	-0,001	0,012	-0,029	
Mean depend var	9,861	S.D. depend var	0,429	
Sum squared resid	46,329	S.E. of regression	0,435	
Log-likelihood	-143,70	Akaike criterion	291,404	
Schwarz criterion	298,415	Hannan-Quinn	294,227	

F47 – Panel-regressziós eredmények a reálkibocsátásra, öt éves késleltetéssel, független változó: súlyozatlan hálózathálóból számolt relatív skálafüggetlenség

	Coefficient	St. hiba	t-stat.	
const	9,437	0,096	98,814	***
log_SCALE_W	0,116	0,013	8,856	***
Mean depend var	9,716	S.D. depend var	0,474	
Sum squared resid	59,001	S.E. of regression	0,446	
Log-likelihood	-181,42	Akaike criterion	366,847	
Schwarz criterion	374,234	Hannan-Quinn	369,804	

F48 – Panel-regressziós eredmények a reálkibocsátásra, késleltetés nélkül, független változó: súlyozott hálózathálóból számolt relatív skálafüggetlenség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,502	0,095	99,893	***
log_SCALE_W	0,101	0,013	7,651	***
Mean depend var	9,733	S.D. depend var	0,470	
Sum squared resid	55,874	S.E. of regression	0,444	
Log-likelihood	-172,21	Akaike criterion	348,419	
Schwarz criterion	355,724	Hannan-Quinn	351347	

F49 – Panel-regressziós eredmények a reálkibocsátásra, egy éves késleltetéssel, független változó: súlyozott hálózathól számolt relatív skálafüggetlenség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,517	0,096	99,523	***
log_SCALE_W	0,101	0,013	7,8002	***
Mean depend var	9,749	S.D. depend var	0,466	
Sum squared resid	52,465	S.E. of regression	0,441	
Log-likelihood	-162,05	Akaike criterion	328,092	
Schwarz criterion	335,296	Hannan-Quinn	330,984	

F50 – Panel-regressziós eredmények a reálkibocsátásra, két éves késleltetéssel, független változó: súlyozott hálózathól számolt relatív skálafüggetlenség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,555	0,096	99,710	***
log_SCALE_W	0,090	0,012	7,234	***
Mean depend var	9,766	S.D. depend var	0,460	
Sum squared resid	49,585	S.E. of regression	0,439	
Log-likelihood	-	Akaike criterion	310,658	
	153,3329			
Schwarz criterion	317,764	Hannan-Quinn	313515	

F51 – Panel-regressziós eredmények a reálkibocsátásra, három éves késleltetéssel, független változó: súlyozott hálózathól számolt relatív skálafüggetlenség

	<i>Coefficient</i>	<i>St. hiba</i>	<i>t-stat.</i>	
const	9,563	0,097	98,643	***
log_SCALE_W	0,095	0,012	7,865	***
Mean depend var	9,784	S.D. depend var	0,455	
Sum squared resid	45,943	S.E. of regression	0,434	
Log-likelihood	-142,592	Akaike criterion	289,183	
Schwarz criterion	296,186	Hannan-Quinn	292,003	

F52 – Panel-regressziós eredmények a reálkibocsátásra, négy éves késleltetéssel, független változó: súlyozott hálózathól számolt relatív skálafüggetlenség

	y	p	K	w	k
Brandenburg	12879	5,069	0,0212	0,0486	0,0137
Mecklenburg-Vorpommern	5933	5,694	0,0183	0,0486	0,0143
Chemnitz	2330	6,551	0,0154	0,0486	0,0112
Dresden	11114	5,182	0,0206	0,0486	0,0061
Leipzig	3854	6,075	0,0169	0,0486	0,0150
Sachsen-Anhalt	11839	5,133	0,0209	0,0486	0,0153
Thüringen	7220	5,529	0,0190	0,0486	0,0085
Île de France	124841	3,605	0,0323	0,0486	0,0089
Champagne-Ardenne	832	7,644	0,0127	0,0486	0,0112
Picardie	1390	7,079	0,0140	0,0486	0,0096
Haute-Normandie	1095	7,336	0,0134	0,0486	0,0075
Centre	5585	5,746	0,0181	0,0486	0,0126
Basse-Normandie	6738	5,586	0,0188	0,0486	0,0151
Bourgogne	3681	6,116	0,0168	0,0486	0,0131
Nord - Pas-de-Calais	7374	5,511	0,0191	0,0486	0,0156
Lorraine	2522	6,474	0,0156	0,0486	0,0128
Alsace	5489	5,761	0,0181	0,0486	0,0145
Franche-Comté	1828	6,794	0,0147	0,0486	0,0072
Pays de la Loire	7747	5,470	0,0193	0,0486	0,0116
Bretagne	36686	4,332	0,0257	0,0486	0,0161
Poitou-Charentes	1641	6,904	0,0144	0,0486	0,0120
Aquitaine	5035	5,836	0,0178	0,0486	0,0125
Midi-Pyrénées	19841	4,751	0,0230	0,0486	0,0156
Limousin	421	8,468	0,0112	0,0486	0,0103
Rhône-Alpes	33510	4,392	0,0253	0,0486	0,0096
Auvergne	1950	6,728	0,0149	0,0486	0,0130
Languedoc-Roussillon	8029	5,441	0,0194	0,0486	0,0143
Provence-Alpes-Côte d'Azur	44087	4,215	0,0266	0,0486	0,0125
Tees Valley and Durham	1795	6,812	0,0147	0,0486	0,0102
Northumberl., Tyne and Wear	3685	6,115	0,0168	0,0486	0,0142
Cumbria	980	7,459	0,0131	0,0486	0,0126
Cheshire	3822	6,082	0,0169	0,0486	0,0108
Greater Manchester	11948	5,126	0,0209	0,0486	0,0127
Lancashire	2403	6,521	0,0155	0,0486	0,0074
Merseyside	2308	6,560	0,0154	0,0486	0,0045
East Yorks., North. Lincolns.	1309	7,143	0,0139	0,0486	0,0126
North Yorkshire	3603	6,136	0,0167	0,0486	0,0093
South Yorkshire	5713	5,726	0,0182	0,0486	0,0108
West Yorkshire	11381	5,164	0,0207	0,0486	0,0152
Derbyshire and Nottinghamshire	8472	5,398	0,0196	0,0486	0,0136
Leicesters., Rutland, Northants	6401	5,629	0,0186	0,0486	0,0093
Lincolnshire	2319	6,555	0,0154	0,0486	0,0100
Herefords., Worcesters., Warks	5135	5,819	0,0179	0,0486	0,0092
Shropshire and Staffordshire	2994	6,309	0,0162	0,0486	0,0104
West Midlands	10501	5,226	0,0204	0,0486	0,0101

	<i>y</i>	<i>p</i>	<i>K</i>	<i>w</i>	<i>k</i>
East Anglia	27925	4,513	0,0245	0,0486	0,0061
Bedfordshire, Hertfordshire	11736	5,140	0,0208	0,0486	0,0090
Essex	8443	5,400	0,0196	0,0486	0,0057
London	117986	3,636	0,0320	0,0486	0,0097
Berks,, Bucks and Oxfords.	27071	4,534	0,0243	0,0486	0,0065
Surrey, East and West Sussex	25168	4,584	0,0240	0,0486	0,0102
Hampshire and Isle of Wight	22863	4,651	0,0236	0,0486	0,0107
Kent	5400	5,775	0,0180	0,0486	0,0087
Gloucesters., Wilts. and Bristol	29998	4,465	0,0248	0,0486	0,0084
Dorset and Somerset	7585	5,488	0,0192	0,0486	0,0144
Cornwall and Isles of Scilly	1213	7,225	0,0137	0,0486	0,0112
Devon	5933	5,694	0,0183	0,0486	0,0106
West Wales and The Valleys	4104	6,017	0,0171	0,0486	0,0140
East Wales	7697	5,476	0,0193	0,0486	0,0126
Eastern Scotland	16906	4,866	0,0223	0,0486	0,0132
South Western Scotland	15394	4,935	0,0219	0,0486	0,0183
North Eastern Scotland	2823	6,365	0,0160	0,0486	0,0160
Highlands and Islands	1617	6,919	0,0144	0,0486	0,0115
Northern Ireland	10532	5,224	0,0204	0,0486	0,0161

F54 – A kalibrálás eredményei az egyes régiókra

<i>Régió</i>	<i>GDP</i>	<i>Csop.</i>
Île-de-France	124841	1
London	117986	1
Oberbayern	54193	1
Provence-Alpes-Côte d’Azur	44087	
Bretagne (Zone)	36686	2
Rhône-Alpes	33510	2
Gloucesters., Wilts., N. S.	29998	3
East England	27925	3
Berks., Buck.s., Oxfords.	27071	3
Berlin	26360	3
Surrey, E. and W. Sussex	25168	3
Hampshire and Isle of Wight	22863	3
Köln	22045	3
Midi-Pyrénées	19841	4
Stuttgart	17319	4
Darmstadt	16962	4
Eastern Scotland	16906	4
South Western Scotland	15394	4
Düsseldorf	14171	4
Mittelfranken	13915	4
Hannover	13589	4
Brandenburg	12879	4
Karlsruhe	12778	4

<i>Régió</i>	<i>GDP</i>	<i>Csop.</i>
Greater Manchester	11948	4
Sachsen-Anhalt	11839	4
Hamburg	11741	4
Bedfords. and Hertfords.	11736	4
West Yorkshire	11381	4
Dresden	11114	4
Northern Ireland	10532	5
West Midlands	10501	5
Arnsberg	8817	5
Derbys. and Nottinghams.	8472	5
Essex	8443	5
Detmold	8171	5
Languedoc-Roussillon	8029	5
Pays de la Loire	7747	5
East Wales	7697	5
Dorset and Somerset	7585	5
Nord-Pas-de-Calais	7374	5
Oberpfalz	7350	5
Thüringen	7220	5
Schleswig-Holstein	7190	5
Braunschweig	6951	5
Basse-Normandie	6738	5
Freiburg	6583	5
Leicesters., Rutl., N.hamptons.	6401	5
Tübingen	6280	5
Devon	5933	5
Mecklenburg-Vorpommern	5933	5
Münster	5742	5
South Yorkshire	5713	5
Centre	5585	5
Alsace	5489	5
Kent	5400	5
Herefords., Worcesters., W.s.	5135	5
Schwaben	5131	5
Aquitaine	5035	5
Rheinhessen-Pfalz	4622	5
Bremen	4384	5
Niederbayern	4333	5
W. Wales, The Valleys	4104	5
Lüneburg	3879	5
Oberfranken	3854	5
Leipzig	3854	5
Cheshire	3822	5
N.humberl., Tyne, Wear	3685	5
Bourgogne	3681	5

<i>Régió</i>	<i>GDP</i>	<i>Csop.</i>
North Yorkshire	3603	5
Gießen	3291	5
Weser-Ems	3165	5
Shrops., Staffords.	2994	5
North Eastern Scotland	2823	5
Lorraine	2522	5
Lancashire	2403	5
Chemnitz	2330	5
Lincolnshire	2319	5
Merseyside	2308	5
Unterfranken	2252	5
Kassel	2140	5
Auvergne	1950	5
Franche-Comté	1828	5
Tees Valley and Durham	1795	5
Saarland	1680	5
Koblenz	1673	5
Poitou-Charentes	1641	5
Highlands and Islands	1617	5
Picardie	1390	5
E. Riding, N. Lincolns.	1309	5
Cornwall and Scilly	1213	5
Haute-Normandie	1095	5
Cumbria	980	5
Trier	844	5
Champagne-Ardenne	832	5
Limousin	421	5

F55 – Régiók csoportosítása GDP alapján

<i>Régió</i>	<i>Fokszám</i>	<i>Csop.</i>
Oberbayern	52	1
Île-de-France	48	1
London	45	1
Stuttgart	45	2
Berlin	40	2
Darmstadt	40	2
Karlsruhe	38	2
Mittelfranken	37	2
Köln	37	2
East England	36	2
Berks., Buck.s., Oxfords.	34	2
Dresden	34	2
Hannover	34	2
Gloucesters., Wilts., N. S.	33	2
Tübingen	32	3

<i>Régió</i>	<i>Fokszám</i>	<i>Csop.</i>
Arnsberg	32	3
Rhône-Alpes	31	3
Rheinhessen-Pfalz	31	3
Schwaben	30	3
Düsseldorf	30	3
Surrey, E. and W. Sussex	29	3
Essex	29	3
Braunschweig	29	3
Hampshire and Isle of Wight	28	3
Provence-Alpes-Côte d'Azur	27	3
Oberpfalz	26	3
Freiburg	26	3
Hamburg	26	3
Bedfords. and Hertfords.	25	3
Thüringen	25	3
Münster	24	3
Schleswig-Holstein	23	3
West Midlands	22	4
Merseyside	22	4
Weser-Ems	22	4
Kent	21	4
Unterfranken	21	4
Detmold	21	4
Lüneburg	21	4
Eastern Scotland	20	4
Leicesters., Rutl., N.hamptons.	20	4
Oberfranken	20	4
Niederbayern	20	4
Greater Manchester	19	4
Bretagne	19	4
Brandenburg	19	4
Herefords., Worcesters., W.s.	18	4
Devon	17	4
Koblenz	17	4
South Yorkshire	16	4
Lancashire	16	4
East Wales	15	4
North Yorkshire	15	4
Midi-Pyrénées	15	4
Kassel	15	4
Gießen	15	4
Bremen	15	4
Pays de la Loire	14	4
Sachsen-Anhalt	14	4
Cheshire	13	4

<i>Régió</i>	<i>Fokszám</i>	<i>Csop.</i>
Franche-Comté	13	4
Chemnitz	13	4
Trier	13	4
Dorset and Somrset	12	4
Shropshire and Staffordshire	12	4
Lincolnshire	12	4
Derbys. and Nottinghams.	12	4
West Yorkshire	11	5
Haute-Normandie	11	5
Northern Ireland	10	5
Tees Valley and Durham	10	5
Aquitaine	10	5
Mecklenburg-Vorpommern	10	5
Languedoc-Roussillon	9	5
Alsace	9	5
Centre	9	5
West Wales and The Valleys	8	5
Basse-Normandie	8	5
Picardie	8	5
Saarland	8	5
South Western Scotland	7	5
Cornwall and Scilly	7	5
Poitou-Charentes	7	5
Nord-Pas-de-Calais	7	5
Bourgogne	7	5
N.humberl., Tyne, Wear	6	5
Leipzig	6	5
Highlands and Islands	5	5
Lorraine	5	5
Auvergne	4	5
E. Riding, N. Lincolns.	3	5
Champagne-Ardenne	3	5
Limousin	2	5
Cumbria	1	5
North Eastern Scotland	0	5

F56 – Régiók csoportosítása fokszám alapján

Ábrák jegyzéke

2.1. Tipikus kis világ hálózati struktúra	25
2.2. Tipikus skálafüggetlen hálózati struktúra	27
3.1. Klaszterezettség és átlagos elérési úthossz a Watts-Strogatz modellben	61
3.2. Skálafüggetlenség a módosított Barabási-Albert modellben	65
4.1. Az aggregált kibocsátás alakulása a Watts-Strogatz modell p paraméterének függvényében	74
4.2. A vállalatok egyedi kibocsátási szintjeinek relatív szórása a Watts-Strogatz modell p paraméterének függvényében	76
4.3. A modell p és ρ paramétereinek hatása az aggregált kibocsátásra a Watts-Strogatz modellben	77
4.4. A modell p és θ paramétereinek hatása az aggregált kibocsátásra a Watts-Strogatz modellben	79
4.5. Az aggregált kibocsátás alakulása a módosított Barabási-Albert modell r paraméterének függvényében	82
4.6. A vállalatok egyedi kibocsátási szintjeinek relatív szórása a módosított Barabási-Albert modell r paraméterének függvényében	83
4.7. A modell p és ρ paramétereinek hatása az aggregált kibocsátásra a módosított Barabási-Albert modellben	83
4.8. A modell p és θ paramétereinek hatása az aggregált kibocsátásra a módosított Barabási-Albert modellben	84
4.9. A modell p és μ paramétereinek hatása az aggregált kibocsátásra a Watts-Strogatz modellben	87
4.10 A modell p és μ paramétereinek hatása a vállalatok egyedi kibocsátási szintjeinek relatív szórására a Watts-Strogatz modellben	88
4.11 A modell r és μ paramétereinek hatása az aggregált kibocsátásra a módosított Barabási-Albert modellben	88
4.12 A modell r és μ paramétereinek hatása a vállalatok egyedi kibocsátási szintjeinek relatív szórására a módosított Barabási-Albert modellben	89

4.13A modell p és ρ paramétereinek hatása a kibocsátás változására a Watts-Strogatz modellben	91
4.14A modell r és δ paramétereinek hatása a kibocsátás változására a módosított Barabási-Albert modellben	93
4.15A modell r és δ paramétereinek hatása a vállalatok kibocsátási szintjei szóródásának változására a módosított Barabási-Albert modellben	94
4.16Technológiai sokk dinamikus hatása a Watts-Strogatz modellben a hálózati struktúra függvényében	97
4.17Technológiai sokk dinamikus hatása a módosított Barabási-Albert modellben a hálózati struktúra függvényében, $\delta = 0$ esetén	98
4.18Technológiai sokk dinamikus hatása a módosított Barabási-Albert modellben a hálózati struktúra függvényében, $\delta = 0,5$ esetén	99
4.19Technológiai sokk dinamikus hatása a módosított Barabási-Albert modellben a hálózati struktúra függvényében, $\delta = 1$ esetén	100
4.20A kibocsátás növekedési ütemének alakulása különböző hálózati modellek és struktúrák mellett	102
4.21A kibocsátás alakulása különböző hálózati modellek és struktúrák mellett átmeneti technológiai sokk esetén, $h = 0,5$ esetén	103
5.1. Egy példa szabadalmi feltalálói együttműködésekre	108
5.2. Interregionális hálózatok felépítésének két módszere az 5.1. ábra példája alapján	109
5.3. A foglalkoztatottság és a GDP közötti összefüggés három európai országban, NUTS2 régióként	114
5.4. A c^1 és c^2 változók közötti összefüggés grafikus szemléltetése	116
5.5. A high-tech szektor termelési függvényének képe különböző korrekciós tényezőkkel számolva	117
5.6. Különböző módszerrel becsült TFP értékek közötti összefüggés	119
5.7. A külső tudásmennyiség becsült regressziós együtthatója a Watts-Strogatz modellben, $\rho = 0,5$ esetén	135
5.8. A külső tudásmennyiség becsült regressziós együtthatója a Watts-Strogatz modellben, $\rho = 1,0$ esetén	136
5.9. A külső tudásmennyiség becsült regressziós együtthatója a Watts-Strogatz modellben, $\rho = 1,5$ esetén	136
5.10A külső tudásmennyiség becsült regressziós együtthatója a módosított Barabási-Albert modellben, $\rho = 0,5$ esetén	137
5.11A külső tudásmennyiség becsült regressziós együtthatója a módosított Barabási-Albert modellben, $\rho = 1,0$ esetén	138
5.12A külső tudásmennyiség becsült regressziós együtthatója a módosított Barabási-Albert modellben, $\rho = 1,50$ esetén	138

6.1. Súlyozott sűrűség alakulása az aggregált hálózatban	146
6.2. Bináris sűrűség alakulása az aggregált hálózatban	147
6.3. Az aggregált hálózat kis világ jellegének alakulása	149
6.4. Az aggregált hálózat skálafüggetlenségének alakulása	150
6.5. A kis világ és a skálafüggetlenségi mutató alakulása Magyarországon, 1981 és 2001 között (1981 = 1)	152
6.6. Hazai NUTS3 régiók közötti szabadalmi együttműködési hálózat 1981-ben	153
6.7. Hazai NUTS3 régiók közötti szabadalmi együttműködési hálózat 1990-ben	154
6.8. Hazai NUTS3 régiók közötti szabadalmi együttműködési hálózat 2000-ben	155
7.1. A TFP és a külső tudás közötti kapcsolat regressziós együtthatója θ függvényében . . .	163
7.2. A TFP és a külső tudás közötti kapcsolat regressziós együtthatója θ függvényében, $0 \leq \theta \leq 1$	164
7.3. A gazdasági és hálózati centralitás közötti összefüggés	169
7.4. A gazdasági centrumot érintő technológiai sokk hatása a GDP-re az öt, GDP szerint képzett csoportban	170
7.5. A GDP változása az egyes régiócsoportokban különböző csoportokat érintő technológiai sokkhatások esetén, GDP szerinti csoportosításban	171
7.6. A GDP változása az egyes régiócsoportokban különböző csoportokat érintő technológiai sokkhatások esetén, fokszám szerinti csoportosításban	172
7.7. Az aggregált GDP alakulása különböző régiócsoportokat érintő technológiai sokkok esetén, GDP szerinti csoportosításban	173
7.8. A regionális GDP értékek szóródásának alakulása különböző régiócsoportokat érintő technológiai sokkok esetén, GDP szerinti csoportosításban	173
7.9. A GDP alakulása csoportonként, különböző mértékű technológiai sokkok esetén, GDP szerinti csoportosításban	174

Táblázatok jegyzéke

4.1. Alkalmazott DSGE modellek strukturális paramétereirei	72
4.2. OLS regresszió Monte Carlo szimulációk alapján, a Watts-Strogatz modellben, eredményváltozó: Y	80
4.3. OLS regresszió Monte Carlo szimulációk alapján, a Watts-Strogatz modellben, eredményváltozó: w	81
4.4. OLS regresszió Monte Carlo szimulációk alapján, a módosított Barabási-Albert modellben, eredményváltozó: Y	84
4.5. OLS regresszió Monte Carlo szimulációk alapján, a módosított Barabási-Albert modellben, eredményváltozó: w	85
5.1. Hálózati kapcsolatok stabilitása a szabadalmi együttműködések 1 és 4 éves aggregálása esetén	111
5.2. Panel regresszió eredményei a teljes gazdaság termelési függvényére vonatkozóan	114
5.3. OLS regresszió eredményei a két korrekciós tényező vonatkozásában	115
5.4. Panel regresszió eredményei a high-tech szektor termelési függvényére vonatkozóan, szabadalom-alapú korrekció esetén	117
5.5. Panel regresszió eredményei a high-tech szektor termelési függvényére vonatkozóan, foglalkoztatás-alapú korrekció esetén	118
5.6. Becsült TFP értékek a teljes gazdaságra és a high-tech szektorra	119
5.7. A tudás-aggregátor becslésének regressziós eredményei a high-tech szektorra vonatkozóan, eredményváltozó: régiós TFP	126
5.8. A tudás-aggregátor becslésének regressziós eredményei a teljes gazdaságra vonatkozóan, eredményváltozó: régiós TFP	127
5.9. Regressziós eredmények korrigált magyarázó változókkal, eredményváltozó: régiós TFP	129
5.10. Regressziós eredmények korrigált magyarázó változókkal, eredményváltozó: korrigált régiós TFP	131
5.11. Regressziós eredmények növekedési rátákkal	132
6.1. A sűrűség alakulása egyes európai országokban	148
6.2. A kis világ mutató alakulása egyes európai országokban	149

6.3. A skálafüggetlenség alakulása egyes európai országokban	151
6.4. Panel-regressziós eredmények a hálózati struktúra és a gazdasági teljesítmény vonatkozásában	156
7.1. Skálafüggetlenség empirikus és szimulált értékei	162
. F1 – Régiók teljes listája, becsült TFP értékek szerint, a teljes gazdaságra és a high-tech szektorra vonatkozóan	197
. F2 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, egyszerű összeggel, kooperációs hálózati súlyokkal és súlyozott kapcsolati mátrixszal	198
. F3 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, egyszerű összeggel, szabadalom-számon alapuló hálózati súlyokkal és súlyozott kapcsolati mátrixszal	198
. F4 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, egyszerű összeggel, kooperációs hálózati súlyokkal és bináris kapcsolati mátrixszal	198
. F5 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, egyszerű összeggel, szabadalom-számon alapuló hálózati súlyokkal és bináris kapcsolati mátrixszal	198
. F6 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, gördülő összeggel, kooperációs hálózati súlyokkal és súlyozott kapcsolati mátrixszal	199
. F7 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, gördülő összeggel, szabadalom-számon alapuló hálózati súlyokkal és súlyozott kapcsolati mátrixszal	199
. F8 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, gördülő összeggel, kooperációs hálózati súlyokkal és bináris kapcsolati mátrixszal	199
. F9 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, gördülő összeggel, szabadalom-számon alapuló hálózati súlyokkal és bináris kapcsolati mátrixszal	199
. F10 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, egyszerű összeggel, kooperációs hálózati súlyokkal és súlyozott kapcsolati mátrixszal	200
. F11 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, egyszerű összeggel, szabadalom-számon alapuló hálózati súlyokkal és súlyozott kapcsolati mátrixszal	200
. F12 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, egyszerű összeggel, kooperációs hálózati súlyokkal és bináris kapcsolati mátrixszal	200

. F13 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, egyszerű összeggel, szabadalom-számon alapuló hálózati súlyokkal és bináris kapcsolati mátrixszal	200
. F14 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság szektor adatai alapján, gördülő összeggel, kooperációs hálózati súlyokkal és súlyozott kapcsolati mátrixszal	201
. F15 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, gördülő összeggel, szabadalom-számon alapuló hálózati súlyokkal és súlyozott kapcsolati mátrixszal	201
. F16 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, gördülő összeggel, kooperációs hálózati súlyokkal és bináris kapcsolati mátrixszal	201
. F17 – Panel-regressziós eredmények a tudás-aggregátorra a teljes gazdaság adatai alapján, gördülő összeggel, szabadalom-számon alapuló hálózati súlyokkal és bináris kapcsolati mátrixszal	201
. F18 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó változóval, kooperációs hálózati súlyokkal	202
. F19 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó változóval, szabadalom-számon alapuló hálózati súlyokkal	202
. F20 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó változóval, kooperációs hálózati súlyokkal	202
. F21 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó változóval, szabadalom-számon alapuló hálózati súlyokkal	202
. F22 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó- és eredményváltozóval, egyszerű összeggel, kooperációs hálózati súlyokkal	203
. F23 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó- és eredményváltozóval, egyszerű összeggel, szabadalom-számon alapuló hálózati súlyokkal	203
. F24 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó- és eredményváltozóval, gördülő összeggel, kooperációs hálózati súlyokkal	203
. F25 – Panel-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, korrigált magyarázó- és eredményváltozóval, gördülő összeggel, szabadalom-számon alapuló hálózati súlyokkal	203
. F26 – OLS-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, növekedési rátákkal, korrigált magyarázó változókkal, kooperációs hálózati súlyokkal	204
. F27 – OLS-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, növekedési rátákkal, korrigált magyarázó változókkal, kooperációs hálózati súlyokkal	204

. F28 – OLS-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, növekedési rátákkal, korrigált magyarázó változókkal, szabadalomszámon alapuló hálózati súlyokkal	204
. F29 – OLS-regressziós eredmények a tudás-aggregátorra a high-tech szektor adatai alapján, növekedési rátákkal, korrigált magyarázó változókkal, szabadalomszámon alapuló hálózati súlyokkal	205
. F30 – Panel-regressziós eredmények a reálkibocsátásra, késleltetés nélkül, független változó: relatív klaszterezettség	205
. F31 – Panel-regressziós eredmények a reálkibocsátásra, egy éves késleltetéssel, független változó: relatív klaszterezettség	205
. F32 – Panel-regressziós eredmények a reálkibocsátásra, két éves késleltetéssel, független változó: relatív klaszterezettség	205
. F33 – Panel-regressziós eredmények a reálkibocsátásra, három éves késleltetéssel, független változó: relatív klaszterezettség	206
. F34 – Panel-regressziós eredmények a reálkibocsátásra, négy éves késleltetéssel, független változó: relatív klaszterezettség	206
. F35 – Panel-regressziós eredmények a reálkibocsátásra, öt éves késleltetéssel, független változó: relatív klaszterezettség	206
. F36 – Panel-regressziós eredmények a reálkibocsátásra, késleltetés nélkül, független változó: relatív elérési úthossz	206
. F37 – Panel-regressziós eredmények a reálkibocsátásra, egy éves késleltetéssel, független változó: relatív elérési úthossz	207
. F38 – Panel-regressziós eredmények a reálkibocsátásra, két éves késleltetéssel, független változó: relatív elérési úthossz	207
. F39 – Panel-regressziós eredmények a reálkibocsátásra, három éves késleltetéssel, független változó: relatív elérési úthossz	207
. F40 – Panel-regressziós eredmények a reálkibocsátásra, négy éves késleltetéssel, független változó: relatív elérési úthossz	207
. F41 – Panel-regressziós eredmények a reálkibocsátásra, öt éves késleltetéssel, független változó: relatív elérési úthossz	208
. F42 – Panel-regressziós eredmények a reálkibocsátásra, késleltetés nélkül, független változó: súlyozatlan hálózatból számolt relatív skálafüggetlenség	208
. F43 – Panel-regressziós eredmények a reálkibocsátásra, egy éves késleltetéssel, független változó: súlyozatlan hálózatból számolt relatív skálafüggetlenség	208
. F44 – Panel-regressziós eredmények a reálkibocsátásra, két éves késleltetéssel, független változó: súlyozatlan hálózatból számolt relatív skálafüggetlenség	208
. F45 – Panel-regressziós eredmények a reálkibocsátásra, három éves késleltetéssel, független változó: súlyozatlan hálózatból számolt relatív skálafüggetlenség	209
. F46 – Panel-regressziós eredmények a reálkibocsátásra, négy éves késleltetéssel, független változó: súlyozatlan hálózatból számolt relatív skálafüggetlenség	209

