

TÉZISFÜZET

Gravitációs modell a vállalati beruházási áramlások- és gépi tanulási megközelítések az európai keretprogramok együttműködési- hálózatának vizsgálatára

Szerző:

KIRÁLY Ferenc

Témavezető:

Prof. Dr. habil. KOSZTYÁN Zsolt Tibor



PANNON EGYETEM

Veszprém
2025. augusztus

Bevezetés

Az Európai Uniót meghatározó gazdasági és kutatási interakciók komplex struktúrája jelentős elemzési kihívásokat vet fel. E kapcsolatok szerkezetének és dinamikájának megértése kulcsfontosságú a döntéshozók, szabályozó hatóságok, nemzeti kormányzatok, valamint a legkisebbtől a legnagyobbig terjedő vállalati szereplők számára. A jelen disszertáció e kontextuson belül két alapvető hálózattípust vizsgál: a vállalati tulajdonosi hálózatokat, amelyek a beruházások és az irányítási viszonyok áramlását tárják fel, valamint a kutatási együttműködési hálózatokat, amelyek az innováció és a tudástranszfer alapját képezik. Az európai gazdasági integráció és a kutatási együttműködések mintázatainak rendszerszintű elemzése elengedhetetlen a hálózatképződési mechanizmusok feltárása és a jövőbeli folyamatok előrejelzése szempontjából. A tulajdonosi és együttműködési hálózatok Európai Unión belüli vizsgálata napjainkra kiemelt kutatási területté vált, mivel ezek a hálózatok alapvetően formálják a tagállamok közötti gazdasági áramlásokat, innovációs mintázatokat és a regionális fejlődést.

A tulajdonosi hálózatok elemzését több, egymással összefonódó gazdasági, szabályozási és társadalmi indok motiválja. Az ilyen hálózatok vizsgálata rávilágít a vállalatokon belüli hierarchikus struktúrákra és azok összekapcsoltságára, így feltárva az eszközök feletti ellenőrzés és a döntéshozatali folyamatok dinamikáját. E struktúrák mélyebb megértése alapvető fontosságú az érintettek számára, beleértve a szabályozó hatóságokat is, mivel ez megalapozza az átláthatóságot és elszámoltathatóságot biztosító szabályozási keretek kialakítását (Lidith Jeude u. a., 2019; Takács u. a., 2018). Emellett a tulajdonosi hálózatok révén feltárhatók azok a komplex összefüggések is, amelyek monopolisztikus viselkedéshez vagy versenykorlátozó gyakorlatokhoz vezethetnek, jelentős hatással a piaci hatékonyságra és gazdasági egyenlőségre (Nakamoto u. a., 2019; Villamil u. a., 2024). Módszertani szempontból a hálózattudomány eszköztára eredményesen alkalmazható e struktúrák feltérképezésére, amely révén új, innovatív keretrendszerek alakíthatók ki a vállalati hierarchiák többrétegűségére, illetve a tulajdonosi kapcsolatokban rejlő komplexitás feltárására (Babić u. a., 2019; Rungi u. a., 2017).

Hasonlóképpen, a kutatási együttműködési hálózatok vizsgálatát az ismeretátadás elősegítése, az innováció ösztönzése, valamint a tudományos közösségeken belüli társadalmi dinamikák megértése motiválja. E hálózatok lehetővé teszik a kutatók közötti interakciókat, amelyek hatással vannak az együttműködések kialakulására és a kutatási produktivitásra. Az ilyen vizsgálatok egyik fő célja a tudományos életben meglévő társadalmi és episztemikus egyenlőtlenségek feltárása és korrigálása (Li u. a., 2022). Az együttműködési hálózatok strukturális konfigurációi hatással vannak az innováció terjedésére is, amelyben a külső együttműködő partnerek meghatározó szerepet játszanak a hálózati dinamika szempontjából (Katerndahl, 2011). E kutatások egyik legfontosabb motivációja az, hogy elősegítsék az ipari K+F hatékonyságát, hiszen a nagy méretű hálózatok gyorsabb tudás- és erőforrás-mobilizációt tesznek lehetővé, amely az innovációs folyamatok gyorsításához elengedhetetlen (Laufs u. a., 2024).

A disszertáció célja, hogy mindkét vizsgálati területen előrelépést biztosítson fejlett modellezési technikák kidolgozásával és alkalmazásával. A tulajdonosi hálózatok esetében egy új, gravitációs alapú modell kerül bemutatásra a beruházási kapcsolatok magyarázatára és előrejelzésére. Az együttműködési hálózatok kapcsán pedig egy átfogó gépi tanulási keretrendszer került kialakításra a Horizon 2020 keretprogramon belüli partnerségek előrejelzésére. A nagyméretű és heterogén adathalmazok integrálásán keresztül mélyebb és árnyaltabb képet nyújt e hálózatok kialakulását befolyásoló tényezőkről.

E vizsgálatot két fő célkitűzés vezérli, amelyek mindegyike egy-egy hálózattípushoz kapcsolódik.

A kutatás elsődleges célja az európai vállalati tulajdonosi hálózat feltérképezése és modellezése, annak érdekében, hogy részletes képet adjon az Európai Unión belüli beruházási áramlásokról és azok meghatározó tényezőiről. A cél a javasolt gravitációs nullmodell alkalmazásával történő élpredikciós pontosság javítása, valamint a hálózati paraméterek jobb becslése. Ennek keretében azonosításra kerülnek a főbb beruházási közösségek és azok időbeli stabilitása is megítélésre kerül. A cél elérése hozzájárulhat a regionális és nemzeti gazdaságpolitikai döntések megalapozásához.

A második célkitűzés a Horizon 2020 keretprogram kutatási együttműködési hálózatának mélyreható vizsgálata. A cél egy olyan pontos előrejelző modell kialakítása, amely a szervezetek mérhető numerikus jellemzői alapján képes megjósolni az együttműködési kapcsolatokat, és egyúttal azonosítani a hálózat kialakulását befolyásoló tényezőket. Egy ilyen modell támogatást nyújthat a jövőbeli konzorciumok előrejelzésében, valamint az előre nem jelzett – vártnál erősebb vagy gyengébb – együttműködési közösségek azonosítása révén hasznos visszacsatolással szolgálhat a támogatáspolitikák alakítása során.

1.1 Kutatási kérdések

A fent megfogalmazott célkitűzések és azok relevanciájának figyelembevételével a jelen tanulmány az alábbi kutatási kérdésekre kíván választ adni.

KK1: Képes-e a javasolt gravitációs alapú gazdasági nullmodell javítani az élpredikció és a hálózati együttműködők becslésének pontosságát, azonosítani stabil innovációs közösségeket, valamint betekintést nyújtani azok térbeli és időbeli dinamikájába?

KK2: Milyen mértékben befolyásolják a közigazgatási határok a beruházási áramlásokat, és hogyan módosul e hatás, ha a földrajzi távolság kontrollváltozóként kerül bevonásra?

KK3: Képes-e a javasolt modell – egy átfogó adatbázison alkalmazva – a jelenlegi benchmarkokat meghaladó módon növelni a szervezeti együttműködések és a keretprogramokban megjelenő közösségi struktúrák megértését és predikciós pontosságát?

E kutatási kérdések a tulajdonosi és az együttműködési hálózatokra vonatkozó predikciós pontosság növelésének, valamint a hálózati struktúrák kialakulásának háttérben húzódó mechanizmusok azonosításának kettős célját ölelik fel az európai kontextusban.

Kapcsolódó kutatások és kutatási feltételezések

2.1 Elméleti alapok a hálózattudományban

A hálózattudomány jelenti a jelen disszertáció elméleti alapját. A korai, meghatározó modellek, mint például az Erdős–Rényi-féle véletlen gráfmodell (ER-modell), adott számú csomópont és egyenletes élvalószínűség alapján definiálták a hálózatokat (Erdős und Rényi, 1959). Bár e modell alapvető jelentőségű, nem képes megragadni a valós hálózatok jellegzetességeit, például a hatványeloszlású fokszámeloszlást. A kisvilág-hálózat modell, amelyet formálisan Watts und Strogatz (1998) írt le, olyan hálózatokat vezetett be, amelyek magas klaszterezettséggel és rövid átlagos úthosszal rendelkeznek — ilyen struktúrák jellemzőek például a társadalmi és idegrendszeri hálózatokra (Bullmore und Sporns, 2009). Jelentős előrelépést jelentett a Barabási–Albert-féle modell (BA-modell), amely a hálózati növekedést és a preferenciális kapcsolódást is figyelembe vette, ezáltal magyarázatot adott a skálafüggetlen hálózatok kialakulására, melyeket erősen összekapcsolt csomópontok jellemeznek (Barabási und Albert, 1999). E modellek idővel beépültek az elemzési keretrendszerekbe, mint például a közösségetekzési és dinamikus hálózati modellek, melyek célja a valós rendszerek komplexitásának pontosabb megragadása (Farzaneh und Coon, 2022; Rinaldo u. a., 2013).

2.2 Vállalati tulajdonosi hálózatok elemzése

A vállalatirányítási rendszereken belüli tulajdonosi hálózatok vizsgálata jelentős figyelmet kapott az utóbbi években, ahogy a kutatók egyre mélyebb összefüggéseket kívántak feltárni a tulajdonosi struktúrák és különböző vállalati teljesítménymutatók között. Kutatások kimutatták, hogy a tulajdonosi koncentráció jelentős hatást gyakorol az eredménykimutatások informativitására: Sharifi und Jafari (2016) például alacsony információtartalmú jelentéseket társított a koncentrált tulajdonosi szerkezethez. Az egyes tulajdonosok által gyakorolt kontroll közvetlen hatással van a vállalatirányítási struktúrákra, ezáltal a vállalati etikai normákra és viselkedési mintázatokra is (Zattoni, 2011).

Számos tanulmány alkalmazta a hálózattudomány eszközeit a tulajdonosi struktúrák feltérképezésére, így új modellek és keretrendszerek születtek, melyek képesek a vállalati hierarchiák többrétegű jellegének megragadására (Babić u. a., 2019; Rungi u. a., 2017). E komplexitás megértése alapvető ahhoz, hogy megvilágításra kerüljön a globális versenydinamikákra hatással bíró tulajdonosi erőkoncentráció (Vitali u. a., 2011). A tulajdonosi hálózatok vizsgálata így egyszerre gazdasági, szabályozási és társadalmi jelentőséggel bír, mivel képes rávilágítani a hierarchikus viszonyokra és a vállalatok közötti komplex kapcsolatrendszerekre.

Bár az élpredikciós módszerek fejlődtek, a predikciós pontosság továbbra is jelentős kihívást jelent e területen. Két fő ok azonosítható: egyrészt a modellek inherens korlátai, másrészt az adatokból fakadó hiányosságok. Modell oldali szempontból például a Newman und Girvan (2004) által bevezetett konfigurációs modell véletlenszerű hálózati struktúrákat feltételez, és figyelmen kívül hagyja a térbeli vagy gazdasági tényezőket, amelyek befolyásolják az élek kialakulását.

2.3 Együtműködési hálózatok elemzése

Az együtműködési hálózatok vizsgálata alapvető szerepet játszik a partnerségek dinamikájának megértésében különböző tudományterületeken. Ezek a hálózatok nem csupán tudásmegosztási csatornák, hanem hatékony eszközök a globális kihívások kezelésére is. Az együtműködési hálózatok kutatását olyan célok motiválják, mint a tudástranzfer fokozása, az innováció előmozdítása, a tudományos közösségek belső dinamikájának megértése és a kutatások társadalmi hatásának növelése (Li u. a., 2022).

Az egyik legfontosabb mozgatórugó az egyenlőtlenségek – társadalmi és episztemikus – azonosítása és csökkentése. Az együtműködési hálózatok betekintést adnak például abba, hogyan kapcsolódnak egymáshoz a kutatók, ezáltal fény derül az erőforrásokhoz és lehetőségekhez való hozzáférés egyenlőtlenségeire is. A hálózatok szerkezete hatással van az innováció terjedésére, a nemzetközi együtműködések pedig sok esetben pontosabb és megbízhatóbb eredményeket biztosítanak (Katerndahl, 2011; Vanni u. a., 2014).

Az élpredikció az együtműködési hálózatok esetében többféle módszertannal is megközelíthető. A hasonlóságon alapuló technikák lokális struktúrák alapján becslik a kapcsolódási valószínűséget; ide tartozik többek között a közös szomszédok (Common Neighbors, CN) módszere, a Jaccard-együttható, valamint az Adamic-Adar index (Ahmad u. a., 2020; Zhang u. a., 2016). A gépi tanulási algoritmusok növekvő jelentőséget kaptak, mivel képesek feltárni azokat az összetett mintázatokat, amelyeket az egyszerű hasonlósági mérőszámok figyelmen kívül hagynának (Sulaiman u. a., 2017; Wang u. a., 2020).

A Horizon 2020 program keretében vizsgált együtműködési hálózatok elemzése során szintén kihívást jelentett a predikciós pontosság. Korábbi kutatások szerint a különböző algoritmusokkal elért pontosság 0,75 körüli értéknél stagnál (Chen u. a., 2021), ami arra utal, hogy további módszertani fejlesztésekre van szükség a hálózati dinamika komplexitásának megragadásához.

2.4 Kutatási feltételezések

Az irodalmi áttekintés és az azonosított kutatási hiányosságok alapján a következő kutatási feltételezések kerültek megfogalmazásra:

KF1: A tulajdonosi hálózatok kialakulását elsősorban gravitációvezérelt gazdasági elvek határozzák meg, és a gravitációs alapú gazdasági nullmodell előrejelzései pontosabban tükrözik a valós beruházási áramlásokat, mint a kizárólag topológiai jellemzőkre épülő modellek.

KF2: A közigazgatási határok a földrajzi közelségtől függetlenül strukturális töréspontokat hoznak létre a tulajdonosi hálózatokban, és e hatások az időbeli rétegekben is tartósan fennmaradnak.

KF3: A gépi tanulási technikák – beleértve az általános és nem általános megközelítéseket – alkalmasak a Horizon 2020 program együttműködési hálózatában megjelenő kapcsolatok predikciójának javítására, és megfelelő modell alkalmazásával az együttműködéseket befolyásoló tényezők is azonosíthatók.

E feltételezések képezik az alapját azoknak a módszertani megközelítéseknek, amelyek a disszertáció empirikus vizsgálatát vezérlik, mind a tulajdonosi, mind az együttműködési hálózatok tekintetében.

Eredmények

3.1 Tulajdonosi hálózat elemzése: gravitációs alapú gazdasági nullmodell

Az európai vállalati tulajdonosi hálózat elemzéséhez egy új, gravitációs alapú gazdasági nullmodell (GEN) került kidolgozásra. Ez a modell a NUTS 3 szintű régiók közötti tulajdonosi kapcsolatok számát térbeli, gazdasági, technológiai és vállalati pénzügyi indikátorok alapján becsli meg, anélkül, hogy a meglévő hálózati topológiára támaszkodna. A GEN modell teljesítményét két ismert nullmodellhez viszonyítva értékeltük: a Newman und Girvan (2004) által kidolgozott véletlen konfigurációs modellhez, illetve a Expert u. a. (2011) által kidolgozott távolság-függő (térbeli) modellhez.

A GEN modell jobban illeszkedett a megfigyelt adatokhoz, és a legalacsonyabb élpredikációs hibát ($\epsilon^{grav} = 0.0080$) érte el, szemben a térbeli modellel ($\epsilon^{spa} = 0.0112$) és a véletlen modellel ($\epsilon^{NG} = 0.0191$), ahogyan azt az 3.1. ábra szemlélteti.

A regressziós együtthatók alapján megállapítható, hogy a leányvállalatok létrehozását elsősorban a technológiai és gazdasági különbségek mozgatják: a tőke a fejlettebb régiókból az elmaradottabbak felé áramlik. Például a leányvállalatok tipikusan olyan NUTS 3 (megyéknek megfelelő területi egységek) régiókban jelennek meg, ahol alacsonyabb a GDP és kevesebb a szabadalmi bejelentés, mint az anyavállalatok székhelyén.

A GEN modell fejlettebb élpredikációja pontosabb hálózati jellemzők – például centralitás – becslését is lehetővé tette. Az 3.2. ábra a bejövő élekhez kapcsolódó centralitásokat mutatja az európai régiók esetén, kiemelve, hogy a GEN modell becslése jobban közelíti az eredeti hálózat szerkezetét, mint a többi modell. Megfelelően azonosítja, hogy a beruházások vonzása az európai „magországokban” koncentrálódik, míg más modellek túlbecsülik a dél- és közép-európai térségek szerepét.

A GEN modell és közösségetekciós algoritmusok együttes alkalmazásával ún. gazdasági-beruházási közösségek (Economic-Investment Communities, EIC) kerültek azonosításra. Ezek olyan régiócsoportok, amelyek között a befektetési intenzitás meghaladja az adott gazdasági, pénzügyi és technológiai paraméterek alapján várható. Az elemzés kimutatta, hogy e közösségek döntő többsége nemzeti határokon belül struktúrállódik, ami arra utal, hogy az adminisztratív határok továbbra is meghatározó erőként hatnak a beruházások alakulására, amint az a 3.3 ábrán látható. Az időbeli vizsgálat (lásd 3.4 ábra) megmutatta, hogy a vizsgált 2010-2018 közötti időszakban e hatás meglehetősen állandónak tekinthető.




(a) Newman und Girvan (2004) modellje: $\|\mathbf{A} - \mathbf{P}^{NG}\| = \epsilon^{NG} = 0.0191$ (b) Expert u. a. (2011) modellje: $\|\mathbf{A} - \mathbf{P}^{spa}\| = \epsilon^{spa} = 0.0112$ (c) GEN modell: $\|\mathbf{A} - \mathbf{P}^{grav}\| = \epsilon^{grav} = 0.0080$

ABBILDUNG 3.1: A különböző nullmodellek illeszkedése (2018)

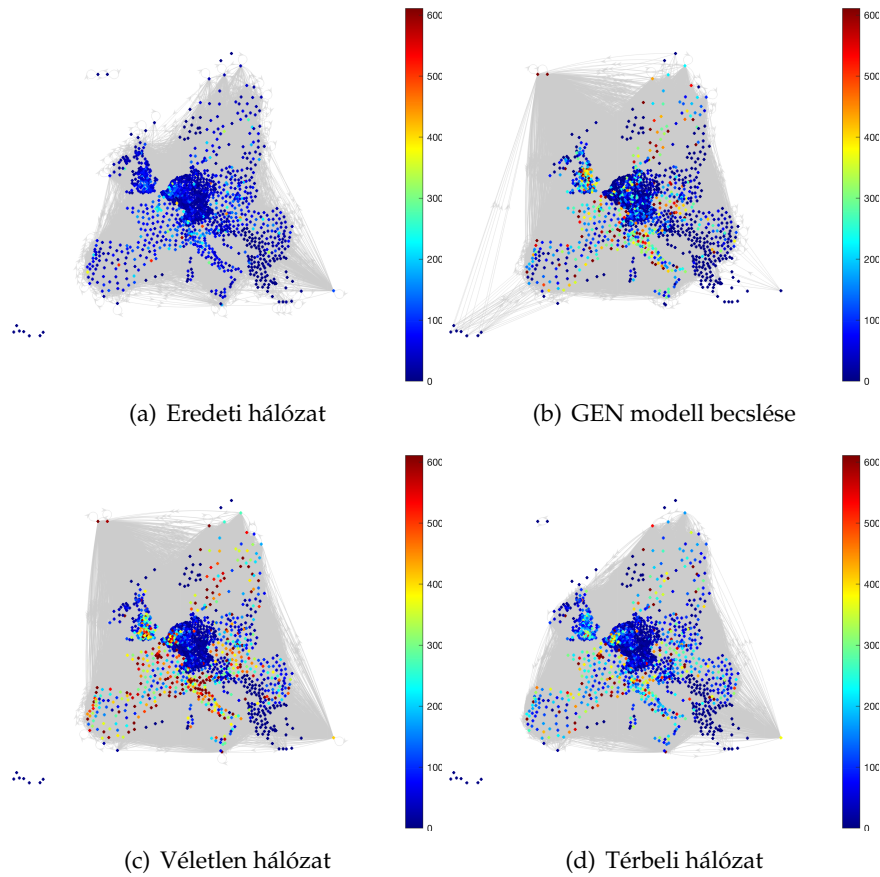


ABBILDUNG 3.2: Bejövő élekhez tartozó fokszám centralitások (2018)

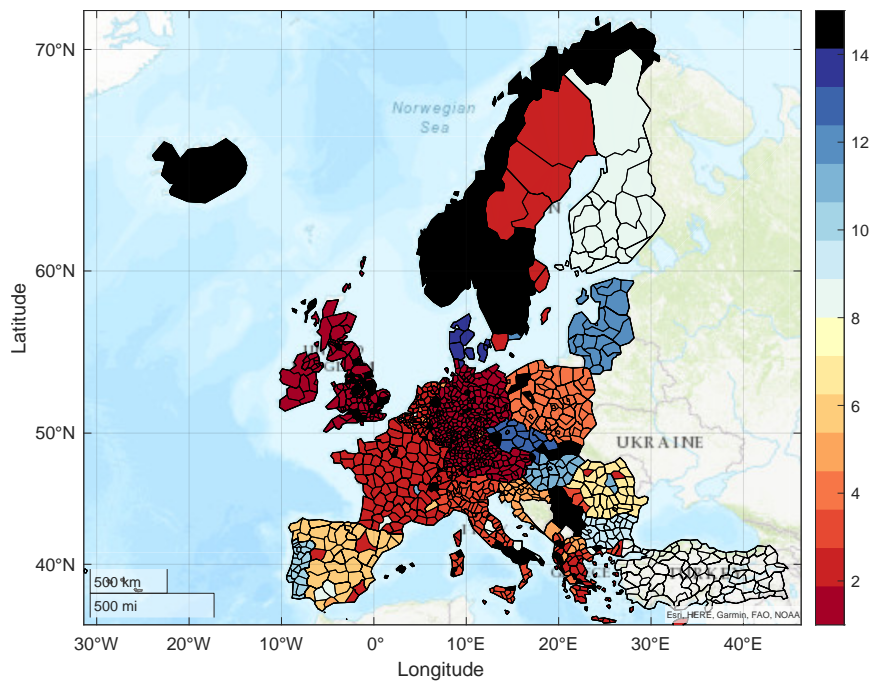


ABBILDUNG 3.3: Gazdasági-beruházási közösségek a GEN modell alapján (2018). A különböző színnel jelölt modulok nagyrészt megfelelnek az államhatároknak.

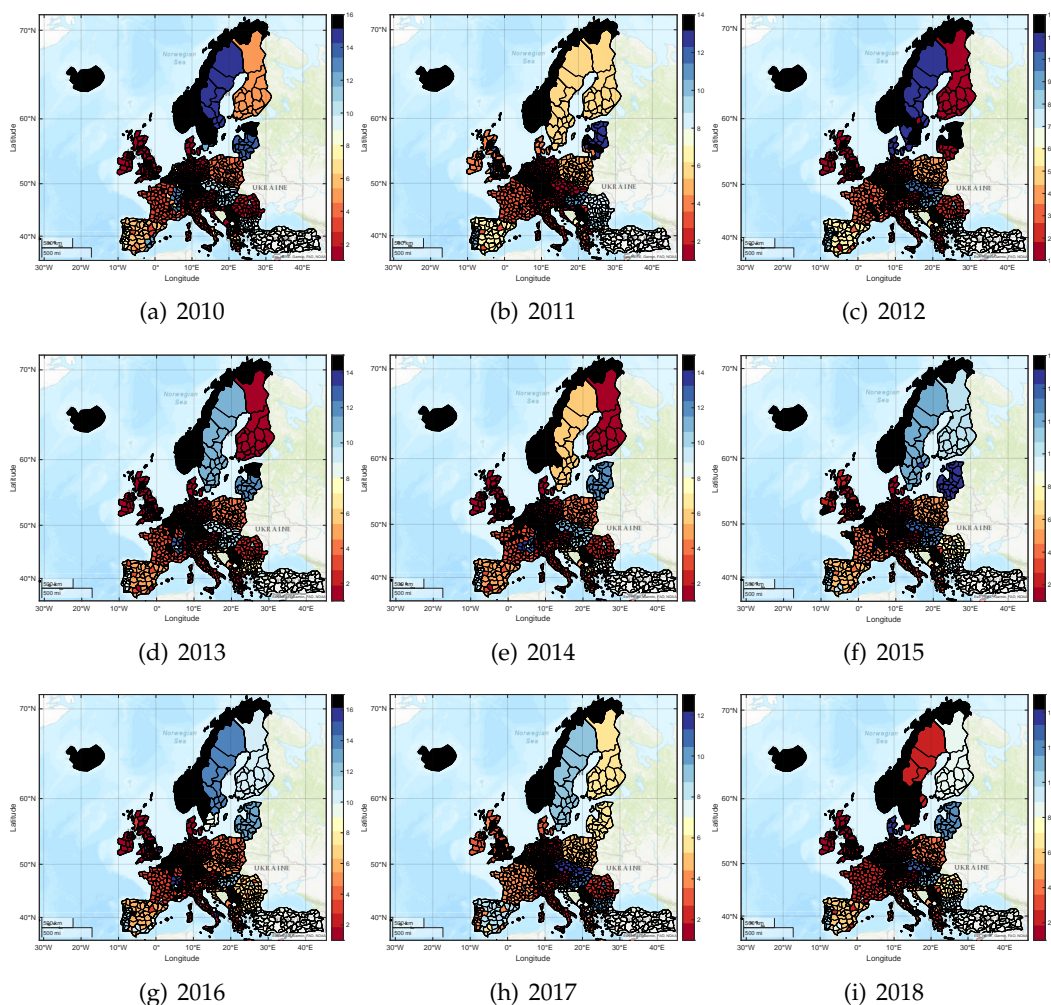


ABBILDUNG 3.4: A gazdasági közösségek rétegenkénti (évenkénti) alakulása (2010–2018)

3.2 A Horizon 2020 keretprogram együttműködési hálózatának elemzése

A Horizon 2020 együttműködési hálózat elemzéséhez egy átfogó kutatási adatbázis került kialakításra, amely a CORDIS, Orbis, Patstat és Eurostat adatbázisok integrációjával jött létre. Ezen adatbázis alapján különböző gépi tanulási modellek kerültek alkalmazásra a szervezetek közötti együttműködési kapcsolatok előrejelzésére.

A változók fontosságát vizsgáló elemzés a Boruta algoritmus és a Random Forest módszer alkalmazásával készült, amely a tanulmány egyik legfontosabb eredményét szolgáltatja. Amint azt az 3.5. ábra mutatja, az együttműködéshez kapcsolódó változók bizonyultak a legmeghatározóbb élképző prediktoroknak. Különösen az elnyert támogatás összege (EC) és a párhuzamos projektvégrehajtások átlagos száma (MULTI) szerepelt kiemelkedő súllyal, még a földrajzi távolságot is megelőzve. Ez erős preferenciális kapcsolódási mechanizmust jelez, amely szerint azok a szervezetek, amelyek kiterjedt kapcsolathálóval és több projekt lebonyolításában szerzett tapasztalattal rendelkeznek, nagyobb valószínűséggel válnak új együttműködések célpontjává.




ABBILDUNG 3.5: A Boruta algoritmus által meghatározott változók fontossági sorrendje. Az együttműködéshez kapcsolódó változók szerepelnek a legfontosabb prediktorokként.

A különböző gépi tanulási algoritmusok él-predikciós teljesítménye is kiértékelésre került. Az ún. „fekete doboz” (black-box) típusú modellek, mint a Random Forest (RF) és az XGBoost, felülmúlták az általános, lineáris megközelítéseket, például a lineáris diszkriminancia-analízist (LDA) és a logisztikus regressziót (LogR). Ez azt jelzi, hogy az adatokban jelentős nemlineáris összefüggések vannak jelen. A finomhangolt XGBoost modell érte el a legmagasabb pontosságot (0,863) és F1 értéket (0,911) a tesztadathalmazon. Amikor az egész hálózatra alkalmaztuk a modelleket, az RF és XGBoost algoritmusok egyaránt magas pontosságot (0,96 feletti) mutattak, és csak minimális strukturális eltérés volt tapasztalható a prediktált és az eredeti hálózat között.

Az él-predikciós modell ezt követően nullmodellként került alkalmazásra annak érdekében, hogy azonosíthatóak legyenek az ún. atipikus együttműködési közösségeket – azaz olyan szervezetcsoportok, amelyekben a megfigyelt együttműködések száma jelentősen meghaladta a modell által vártat. Ezek a közösségek – ahogy az 3.6. ábrán látható – földrajzilag elsősorban az EU mag-államaiban koncentrálnak, különösen Németországban és az Egyesült Királyságban. Ez az eredmény azt jelzi, hogy léteznek olyan önmegerősítő együttműködési klaszterek, amelyek nem magyarázhatók teljes mértékben a modellbe bevont vállalati, gazdasági és technológiai változókkal.

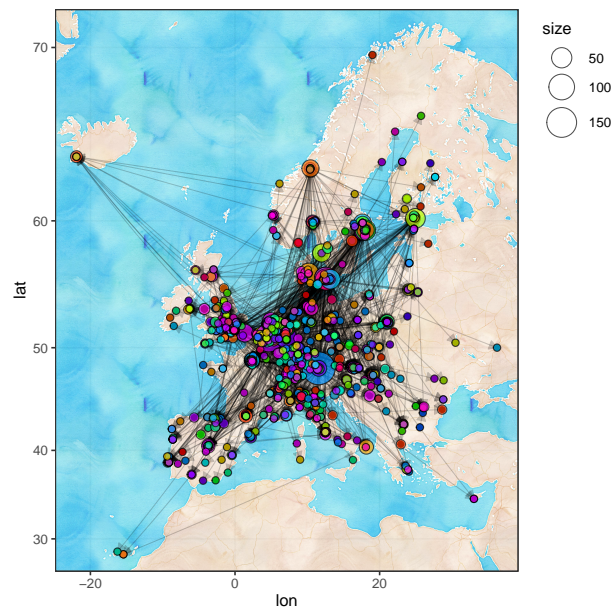


ABBILDUNG 3.6: Gazdasági együttműködési közösségek. A csomópontok szervezeteket, az élek pedig a modell által alulbecsült együttműködések jelölik. A közösségek földrajzilag Nyugat-Európára koncentrálnak.

A kutatás tézisei

A bemutatott eredmények mélyreható elemzésének eredményeként az alábbi tézis kerültek felállításra.

KT1: A disszertációban bemutatásra került, hogy a gravitációs alapú gazdasági nullmodell alacsonyabb élpredikciós hibát eredményez a Newman–Girvan és az Expert-modellekhez képest, továbbá lehetővé teszi gazdasági-beruházási közösségek azonosítását, valamint a származtatott hálózati paraméterek pontosabb becslését is a hivatkozott modellekkel összevetve. A modell eredményei azt is jelezték, hogy az Európai Unión belüli vállalat alapításokat technológiai és gazdasági különbségek befolyásolják, és a beruházási áramlások a fejlettebb régiókból az elmaradottabb térségek felé irányulnak.

KT2: A dolgozatban javasolt gravitációs alapú gazdasági nullmodell rámutatott arra, hogy az elsődleges beruházási áramlásokat erőteljesen befolyásolják a közigazgatási határok (országok közötti határok), mivel a beruházások döntő többsége nemzeti határokon belül valósul meg, így a tőke jellemzően belföldön marad. Annak ellenére, hogy az Európai Unió célja a tagállamok közötti integráció elmélyítése és a gazdasági egyenlőség előmozdítása, a közigazgatási határok továbbra is jelentős hatást gyakorolnak az európai tulajdonosi hálózat kialakulására.

KT2.1: A tanulmányban bemutatott éves szinten alkalmazott modell alkalmas a gazdasági-beruházási közösségek időbeli változásainak azonosítására.

KT3: A disszertációban bemutatott, együttműködési hálózatokra kidolgozott modell – az integrált gépi tanulási technikákkal együtt alkalmazva – felülmúlta a benchmark modellek teljesítményét, és tovább növelte az előrejelzési pontosságot. A 23 validált vállalati és gazdasági prediktor közötti összefüggések feltárásra kerültek, és valamennyi definiált változó jelentősnek bizonyult, ami alátámasztja az átfogó adatbázis alkalmazásának előnyeit. A modell továbbá feltárta, hogy az együttműködések kialakulását leginkább a korábbi, azonos keretprogramon belüli sikeres együttműködések befolyásolják. Az elemzés során atipikus együttműködési közösségek is azonosításra kerültek, amelyek kizárólag az Európai Unió központi tagállamaiban koncentrálódnak.

KT3.1: Az Európai Unió keretprogramjaihoz kapcsolódó együttműködési hálózatok élpredikciója tekintetében a nem általános (non-generic) módszerek jobban teljesítenek, mint az általános megközelítések, ami nemlineáris összefüggések jelenlétére utal a modellben. Az alkalmazott nem általános módszerek közül a Random Forest alapú eljárások bizonyultak a leghatékonyabbnak.

Összefoglalás

A disszertáció hozzájárult az európai gazdasági és kutatási hálózatok mélyebb megértéséhez azáltal, hogy különböző módszertani megközelítések kerültek integrálásra magyarázó modellek keretében.

A vállalati tulajdonosi hálózatok elemzésére egy általánosított, éves szinten alkalmazott gravitációs alapú gazdasági nullmodell (GEN) került kidolgozásra. Ez a modell pontosabb becslést adott a hálózati jellemzőkre és az élpredikcióra vonatkozóan, mint a hagyományos topológia-alapú vagy térbeli modellek. A modell gazdasági, pénzügyi és technológiai mutatók bevonásával sikeresen magyarázta a beruházások áramlását a fejlettebb régiókból a kevésbé fejlett térségek felé az Európai Unión belül. Továbbá, a GEN modell és a közösség kereső módszerek egyesítése révén az Európai Unión belül feltárássra kerültek a gazdasági közösségek (EIC), melyek megmutatták, hogy az adminisztratív határok (ország határok) elsődleges strukturális meghatározó erőként vannak jelen.

A kutatási együttműködések elemzéséhez egy nagy pontosságú élpredikációs modell került kialakításra a Horizon 2020 hálózatra vonatkozóan, több, egymást kiegészítő adatbázis integrálásával. Ez a megközelítés lehetővé tette azoknak a főbb tényezőknek az azonosítását, amelyek meghatározó szerepet játszanak az együttműködések kialakulásában. A legfontosabb befolyásoló tényezők közé a korábbi projekttevékenységben való részvétel, valamint az elnyert támogatási összegek tartoztak. Az elemzés továbbá lehetővé tette olyan együttműködési közösségek azonosítását is, amelyek eltérnek a várttól, és amelyek túlnyomó részt az Európai Unió központi tagállamaiból származó szervezeteket foglalják magukban. Ez a megfigyelés rámutat arra, hogy az együttműködési mintázatok jelentős mértékben koncentráltak, és önmegerősítő jellegű hálózati struktúrák mentén szerveződnek.

5.1 Következtetések és implikációk

A kutatás eredményei jelentős relevanciával bírnak az érintett területeken tevékenykedő döntéshozók és szakpolitikai tervezők számára. Az alábbi következtetések az elemzések alapján születtek, és céljuk, hogy segítsék a stratégiai tervezést és döntéshozatalt.

A tulajdonosi hálózat elemzése rámutatott, hogy a beruházások áramlása túlnyomórészt a gazdaságilag fejlettebb régiókból a kevésbé fejlett térségek felé irányul. Ez a megállapítás alapul szolgálhat a kormányzati szervek számára annak érdekében, hogy az infrastruktúra-fejlesztési kezdeményezéseket elsősorban az elmaradott régiókban helyezték előtérbe, ezáltal növelve e területek vonzerejét jövőbeni leányvállalatok létesítésére. Az ilyen célzott beavatkozások hozzájárulhatnak a területi egyenlőtlenségek mérsékléséhez és a kiegyensúlyozott gazdasági fejlődés előmozdításához.

A 2010 és 2018 közötti időszakban tapasztalt időbeli stabilitás azt jelzi, hogy az alapvető gazdasági-beruházási közösségek lényegében változatlanok maradtak. Ez az állandóság arra utal, hogy a beruházások áramlása hosszú távon elsősorban az

Európai Unió gazdasági központjai között zajlik. Ezt az egyensúlyt azonban tudatos szakpolitikai eszközökkel – például adókedvezmények bevezetésével vagy szabályozási feltételek módosításával – potenciálisan át lehetne alakítani oly módon, hogy a beruházások más célterületek felé terelődjenek.

A Horizon H2020 kutatási együttműködési hálózat vizsgálata szintén több szempontból releváns megállapítással szolgált. Az élkialakulás skálafüggetlen jellegéből az következik, hogy azok a szervezetek, amelyek már rendelkeznek korábbi együttműködési tapasztalattal, lényegesen nagyobb valószínűséggel képesek újabb partnerségek kialakítására, mint az újonnan belépők. Ennek következtében a Keretprogramok (FP) tervezői számára érdemes megfontolni olyan felső korlátok bevezetését, amelyek egy adott szervezet által elnyerhető projektek számát – akár szervezeti méret alapján differenciálva – korlátoznák, elősegítve ezáltal az egyenlő részvételi lehetőségeket.

Továbbá célszerű lehet speciális szabályozási elemek bevezetése is, amelyek kifejezetten az olyan szervezetek részvételét ösztönöznék, amelyek korábban nem vettek részt támogatott (FP) projektekben. Az alkalmassági kritériumok enyhítése vagy célzott támogatási mechanizmusok biztosítása révén ezek az intézkedések hozzájárulhatnak a részvételi kör szélesítéséhez és a programokon belüli sokszínűség fokozásához.

5.2 A Kutatási összefoglaló táblázata

Az alábbi táblázat a kutatási kérdéseket, feltételezéseket és téziseket együttesen, áttekinthető formában tartalmazza.

TABELLE 5.1: Kutatási kérdések, feltételezések és tézisek összefoglaló táblázata

Ref.	Állítás
KK1:	Képes-e a javasolt gravitációs alapú gazdasági nullmodell javítani az élpredikció és a hálózati együttthatók becslésének pontosságát, azonosítani stabil innovációs közösségeket, valamint betekintést nyújtani azok térbeli és időbeli dinamikájába?
KF1:	A tulajdonosi hálózatok kialakulását elsősorban gravitációvezérelt gazdasági elvek határozzák meg, és a gravitációs alapú gazdasági nullmodell előrejelzései pontosabban tükrözik a valós beruházási áramlásokat, mint a kizárólag topológiai jellemzőkre épülő modellek.
KT1:	A disszertációban bemutatásra került, hogy a gravitációs alapú gazdasági nullmodell alacsonyabb élpredikciós hibát eredményez a Newman–Girvan- és az Expert-modellekhez képest, továbbá lehetővé teszi gazdasági-beruházási közösségek azonosítását, valamint a származtatott hálózati paraméterek pontosabb becslését is a hivatkozott modellekkel összevetve. A modell eredményei azt is jelezték, hogy az Európai Unión belüli vállalatalapításokat technológiai és gazdasági különbségek befolyásolják, és a beruházási áramlások a fejlettebb régiókból az elmaradottabb térségek felé irányulnak.
KK2:	Milyen mértékben befolyásolják a közigazgatási határok a beruházási áramlásokat, és hogyan módosul e hatás, ha a földrajzi távolság kontrollváltozóként kerül bevonásra?
KF2:	A közigazgatási határok a földrajzi közelségtől függetlenül strukturális töréspontokat hoznak létre a tulajdonosi hálózatokban, és e hatások az időbeli rétegekben is tartósan fennmaradnak.
KT2:	A dolgozatban javasolt gravitációs alapú gazdasági nullmodell rámutatott arra, hogy az elsődleges beruházási áramlásokat erőteljesen befolyásolják a közigazgatási határok (országok közötti határok), mivel a beruházások döntő többsége nemzeti határokon belül valósul meg, így a tőke jellemzően belföldön marad. Annak ellenére, hogy az Európai Unió célja a tagállamok közötti integráció elmélyítése és a gazdasági egyenlőség előmozdítása, a közigazgatási határok továbbra is jelentős hatást gyakorolnak az európai tulajdonosi hálózat kialakulására.
KT2.1:	A tanulmányban bemutatott éves szinten alkalmazott modell alkalmas a gazdasági-beruházási közösségek időbeli változásainak azonosítására.

Ref.	Állítás
KK3:	Képes-e a javasolt modell – egy átfogó adatbázison alkalmazva – a jelenlegi benchmarkokat meghaladó módon növelni a szervezeti együttműködések és a keretprogramokban megjelenő közösségi struktúrák megértését és predikciós pontosságát?
KF3:	A gépi tanulási technikák – beleértve az általános és nem általános megközelítéseket – alkalmasak a Horizon 2020 program együttműködési hálózatában megjelenő kapcsolatok predikciójának javítására, és megfelelő modell alkalmazásával az együttműködések befolyásoló tényezőik is azonosíthatók.
KT3:	A disszertációban bemutatott, együttműködési hálózatokra kidolgozott modell – az integrált gépi tanulási technikákkal együtt alkalmazva – felülmúlta a benchmark modellek teljesítményét, és tovább növelte az előrejelzési pontosságot. A 23 validált vállalati és gazdasági prediktor közötti összefüggések feltárára kerültek, és valamennyi definiált változó jelentősnek bizonyult, ami alátámasztja az átfogó adatbázis alkalmazásának előnyeit. A modell továbbá feltárta, hogy az együttműködések kialakulását leginkább a korábbi, azonos keretprogramon belüli sikeres együttműködések befolyásolják. Az elemzés során atipikus együttműködési közösségek is azonosításra kerültek, amelyek kizárólag az Európai Unió központi tagállamaiban koncentrálódnak.
KT3.1:	Az Európai Unió keretprogramjaihoz kapcsolódó együttműködési hálózatok élpredikciója tekintetében a nem általános (non-generic) módszerek jobban teljesítenek, mint az általános megközelítések, ami nemlineáris összefüggések jelenlétére utal a modellben. Az alkalmazott nem általános módszerek közül a Random Forest alapú eljárások bizonyultak a leghatékonyabbnak.

5.3 Hozzájárulás a tudományos irodalomhoz

A dolgozat három fő területen járult hozzá a tudományos irodalom bővítéséhez.

Elsőként, a javasolt gravitációs alapú gazdasági nullmodell (GEN), amely a Kosztyán u. a., 2022 publikációban jelent meg, egy újszerű és pontosabb megközelítést kínál a térbeli gazdasági hálózatokban történő élpredikcióra. A modell rámutatott arra, hogy az Európai Unión belüli leányvállalati struktúra elsősorban a gazdasági fejlettségbeli különbségek mentén szerveződik. Ez a megállapítás jelentős következményekkel bír az Európai Unió gazdasági kohézióra irányuló célkitűzései szempontjából. A nemzeti szintű, stabil gazdasági-beruházási közösségek (EIC) azonosítása új típusú szakpolitikai felismerésekhez vezethet.

Másodszor, az együttműködési hálózatok vizsgálatának eredményeként – amely Kosztyán u. a., 2024 publikációban került bemutatásra – egy olyan nagy pontosságú és jól értelmezhető modell került kifejlesztésre, amely kutatás-fejlesztési és innovációs (K+F+I) hálózatok élpredikciójára alkalmas. E modell kialakítását egyedülálló kutatási adatbázis tette lehetővé, amely vállalati, gazdasági, szabadalmi és együttműködési adatokat integrál, ezzel lehetőséget teremtve a korábbinál összetettebb és árnyaltabb elemzésekre.

Harmadszor, az együttműködések kialakulását befolyásoló legfontosabb gazdasági, technológiai, és mindenekelőtt együttműködési múltbeli tényezőik azonosítására

és rangsorolására is sor került. A kidolgozott modell továbbá képes azonosítani azokat az atipikus közösségeket, ahol az együttműködések sűrűsége meghaladja a modell által előre jelzett értéket. Ezáltal hatékony eszközt kínál a kutatási hálózatok mögötti dinamikák feltárására, valamint az együttműködések bővítését és inkluzivitását célzó szakpolitikai beavatkozások megalapozására.

Publikációk

Ebben a fejezetben kerülnek felsorolásra a szerző témához kapcsolódó publikációi, valamint megadásra kerül az MTMT-profil elérhetősége. A publikációk különböző kategóriák szerint csoportosítva jelennek meg.

6.1 A szerző témához kapcsolódó publikációi

A szerző MTMT-profilja elérhető a következő címen: [web-link¹](#), amely tartalmazza az alább felsorolt tudományos közleményeket is.

Nemzetközi folyóirat publikációk

Zsolt T. Kosztyán and **Ferenc Király** and Attila I. Katona and Tibor Csizmadia and Beáta Fehérvölgyi (2024). Analysis and prediction of the Horizon 2020 R&D&I collaboration network. In: *Expert Systems with Applications*
DOI: doi.org/10.1016/j.eswa.2024.124417

Zsolt T. Kosztyán and **Ferenc Király** and Marcell T. Kurbucz, (2022) Analysis of ownership network of European companies using gravity models. In: *Applied Network Science*. DOI: doi.org/10.1007/s41109-022-00501-y

Magyar nyelvű folyóirat publikációk

Zsolt T. Kosztyán and **Ferenc Király** and Marcell T. Kurbucz, (2024). Európai cégek tulajdonosi szerkezetének dinamikus hálózatelemzése. In: *Közgazdasági Szemle*
DOI: [dx.doi.org-/10.18414/KSZ.2024.1.57](https://dx.doi.org/10.18414/KSZ.2024.1.57)

Konferenciák

Zsolt T. Kosztyán and **Ferenc Király**. Analysis of the ownership network of European companies using panel data gravity models. XXV. Tavaszi Szél Konferencia 2022. Pécs, Hungary

¹<https://m2.mtmt.hu/gui2/?type=authors&mode=browse&sel=10043340>

Literatur

- Ahmad, Iftikhar, Akhtar, Muhammad Usman, Noor, Salma und Shahnaz, Ambreen (2020). „Missing Link Prediction Using Common Neighbor and Centrality Based Parameterized Algorithm“. In: *Scientific Reports*. DOI: 10.1038/s41598-019-57304-y.
- Babić, Milan, Garcia-Bernardo, Javier und Heemskerk, Eelke M. (2019). „The Rise of Transnational State Capital: State-Led Foreign Investment in the 21st Century“. In: *Review of International Political Economy*. DOI: 10.1080/09692290.2019.1665084.
- Barabási, Albert-László und Albert, Réka (1999). „Emergence of scaling in random networks“. In: *Science* 286.5439, S. 509–512. DOI: 10.1126/science.286.5439.509.
- Bullmore, Ed und Sporns, Olaf (2009). „Complex brain networks: graph theoretical analysis of structural and functional systems“. In: *Nature Reviews Neuroscience* 10.3, S. 186–198. ISSN: 1471-0048. DOI: 10.1038/nrn2575. URL: <https://doi.org/10.1038/nrn2575>.
- Chen, Wei, Qu, Hui und Chi, Kuo (2021). „Partner selection in China interorganizational patent cooperation network based on link prediction approaches“. In: *Sustainability* 13.2, S. 1003. DOI: <https://doi.org/10.3390/su13021003>.
- Erdős, P. und Rényi, A. (1959). „On random graphs, I“. In: *Publicationes Mathematicae (Debrecen)* 6, S. 290–297.
- Expert, P., Evans, T. S., Blondel, V. D. und Lambiotte, R. (2011). „Uncovering space-independent communities in spatial networks“. In: *Proceedings of the National Academy of Sciences* 108.19, 7663–7668. ISSN: 0027-8424, 1091-6490. DOI: 10.1073/pnas.1018962108.
- Farzaneh, Amirmohammad und Coon, Justin P. (2022). „An Information Theory Approach to Network Evolution Models“. In: *arXiv preprint arXiv:2201.08306*. DOI: 10.48550/arxiv.2201.08306.
- Katerndahl, David A. (2011). „Evolution of the Research Collaboration Network in a Productive Department“. In: *Journal of Evaluation in Clinical Practice*. DOI: 10.1111/j.1365-2753.2011.01791.x.
- Kosztján, Zsolt Tibor, Király, Ferenc und Kurucz, Marcell T (2022). „Analysis of ownership network of European companies using gravity models“. In: *Applied Network Science* 7.1, S. 1–31. DOI: <https://doi.org/10.1007/s41109-022-00501-y>.
- Kosztján, Zsolt T., Király, Ferenc, Katona, Attila I., Csizmadia, Tibor und Fehérvölgyi, Beáta (2024). „Analysis and prediction of the Horizon 2020 R&D&I collaboration network“. In: *Expert Systems with Applications* 255, S. 124417. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2024.124417>. URL: <https://www.sciencedirect.com/science/article/pii/S0957417424012831>.
- Laufs, Daniel, Melnychuk, Tetyana und Schultz, Carsten (2024). „Effects of Prior Knowledge and Collaborations on R&D Performance in Times of Urgency: The Case of <sc>COVID</sc>-19 Vaccine Development“. In: *R and D Management*. DOI: 10.1111/radm.12670.
- Li, Weihua, Zhang, Sam, Zheng, Zhiming, Cranmer, Skyler und Clauset, Aaron (2022). „Untangling the Network Effects of Productivity and Prominence Among Scientists“. In: *Nature Communications*. DOI: 10.1038/s41467-022-32604-6.

- Lidth Jeude, Jeroen van, Aste, Tomaso und Caldarelli, Guido (2019). „The Multilayer Structure of Corporate Networks“. In: *New Journal of Physics*. DOI: 10.1088/1367-2630/ab022d.
- Nakamoto, Tembo, Chakraborty, Abhijit und Ikeda, Yuichi (2019). „Identification of Key Companies for International Profit Shifting in the Global Ownership Network“. In: *Applied Network Science*. DOI: 10.1007/s41109-019-0158-8.
- Newman, M. E. J. und Girvan, M. (2004). „Finding and evaluating community structure in networks“. In: *Physical Review E* 69.2, S. 026113. DOI: 10.1103/PhysRevE.69.026113.
- Rinaldo, Alessandro, Petrović, Sonja und Fienberg, Stephen E. (2013). „Maximum Likelihood Estimation in the β -Model“. In: *The Annals of Statistics* 41.5, S. 2246–2272. DOI: 10.1214/12-aos1078.
- Rungi, Armando, Morrison, Gregory und Pammolli, Fabio (2017). „Global Ownership and Corporate Control Networks“. In: *SSRN Electronic Journal*. DOI: 10.2139/ssrn.3031955.
- Sharifi, Farnoush Amini und Jafari, Seyedeh Mahbubeh (2016). „Cash Flows and Leverage Adjustments“. In: *Accounting*. DOI: 10.5267/j.ac.2016.4.001.
- Sulaimany, Sadegh, Khansari, Mohammad, Zarrineh, Peyman, Daianu, Madelaine, Jahanshad, Neda, Thompson, Paul M. und Masoudi-Nejad, Ali (2017). „Predicting Brain Network Changes in Alzheimer’s Disease With Link Prediction Algorithms“. In: *Molecular Biosystems*. DOI: 10.1039/c6mb00815a.
- Takes, Frank W., Kosters, Walter A., Witte, Boyd und Heemskerk, Eelke M. (2018). „Multiplex Network Motifs as Building Blocks of Corporate Networks“. In: *Applied Network Science*. DOI: 10.1007/s41109-018-0094-z.
- Vanni, Tázio, Mesa-Frias, Marco, Sánchez-García, Rubén J., Roesler, Rafael, Schwartzmann, Gilberto, Goldani, Marcelo Zubarán und Foss, Anna M. (2014). „International Scientific Collaboration in HIV and HPV: A Network Analysis“. In: *Plos One*. DOI: 10.1371/journal.pone.0093376.
- Villamil, Isabela, Kertész, János und Fazekas, Mihály (2024). „Collusion Risk in Corporate Networks“. In: *Scientific Reports*. DOI: 10.1038/s41598-024-53625-9.
- Vitali, Stefania, Glattfelder, James B. und Battiston, Stefano (2011). „The Network of Global Corporate Control“. In: *Plos One*. DOI: 10.1371/journal.pone.0025995.
- Wang, Lei, Ren, Jing, Xu, Bo, Li, Jianxin, Luo, Wei und Xia, Feng (2020). „MODEL: Motif-Based Deep Feature Learning for Link Prediction“. In: *Ieee Transactions on Computational Social Systems*. DOI: 10.1109/tcss.2019.2962819.
- Watts, Duncan J. und Strogatz, Steven H. (1998). „Collective dynamics of ‘small-world’ networks“. In: *Nature* 393.6684, S. 440–442. ISSN: 1476-4687. DOI: 10.1038/30918. URL: <https://doi.org/10.1038/30918>.
- Zattoni, Alessandro (2011). „Who Should Control a Corporation? Toward a Contingency Stakeholder Model for Allocating Ownership Rights“. In: *Journal of Business Ethics*. DOI: 10.1007/s10551-011-0864-3.
- Zhang, Peng, Wang, Xiang, Wang, Futian, Zeng, An und Xiao, Jinghua (2016). „Measuring the Robustness of Link Prediction Algorithms Under Noisy Environment“. In: *Scientific Reports*. DOI: 10.1038/srep18881.