



Területi Statisztika

Közzététel: 2022. május 26.

A tanulmány címe:

A hazai koronavírus-halálozás járási különbségeinek összefüggései az egészségügyi ellátással

Szerzők:

Kovács László – Vántus Katalin

<https://doi.org/10.15196/TS620301>

Az alábbi feltételek érvényesek minden, a Központi Statisztikai Hivatal (a továbbiakban: KSH) Területi Statisztika c. folyóiratában (a továbbiakban: Folyóirat) megjelenő tanulmányra. Felhasználó a tanulmány, vagy annak részei felhasználásával egyidejűleg tudomásul veszi a jelen dokumentumban foglalt felhasználási feltételeket, és azokat magára nézve kötelezőnek fogadja el. Tudomásul veszi, hogy a jelen feltételek megszegéséből eredő valamennyi kárért felelősséggel tartozik.

- 1) A jogszabályi tartalom kivételével a tanulmányok a szerzői jogról szóló 1999. évi LXXVI. törvény (Sztj.) szerint szerzői műnek minősülnek. A szerzői jog jogosultja a KSH.
- 2) A KSH földrajzi és időbeli korlátozás nélküli, nem kizárólagos, nem átadható, térítésmentes felhasználási jogot biztosít a Felhasználó részére a tanulmány vonatkozásában.
- 3) A felhasználási jog keretében a Felhasználó jogosult a tanulmány:
 - a) oktatási és kutatási célú felhasználására (nyilvánosságra hozatalára és továbbítására a 4. pontban foglalt kivétellel) a Folyóirat és a szerző(k) feltüntetésével;
 - b) tartalmáról összefoglaló készítésére az írott és az elektronikus médiában a Folyóirat és a szerző(k) feltüntetésével;
 - c) részletének idézésére – az átvevő mű jellege és célja által indokolt terjedelemben és az eredetihez híven – a forrás, valamint az ott megjelölt szerző(k) megnevezésével.
- 4) A Felhasználó nem jogosult a tanulmány továbbértékesítésére, haszonszerzési célú felhasználására. Ez a korlátozás nem érinti a tanulmány felhasználásával előállított, de az Sztj. szerint önálló szerzői műnek minősülő mű ilyen célú felhasználását.
- 5) A tanulmány átdolgozása, újra publikálása tilos.
- 6) A 3. a)–c.) pontban foglaltak alapján a Folyóiratot és a szerző(ke)t az alábbiak szerint kell feltüntetni:

„Forrás: Területi Statisztika c. folyóirat 62. évfolyam 3. számában megjelent, Kovács László – Vántus Katalin által írt, A hazai koronavírus-halálozás járási különbségeinek összefüggései az egészségügyi ellátással c. tanulmány”

- 7) A Folyóiratban megjelenő tanulmányok kutatói véleményeket tükröznek, amelyek nem esnek szükségképpen egybe a KSH, vagy a szerzők által képviselt intézmények hivatalos álláspontjával.



A hazai koronavírus-halálozás járási különbségeinek összefüggései az egészségügyi ellátással*

The relation between the differences of Coronavirus related deaths in the districts of Hungary and health services

Kovács, László

Budapesti Corvinus Egyetem,
Matematikai és Statisztikai
Modellezés Intézet,
Statisztika Tanszék
E-mail:
laszlo.kovacs2@uni-corvinus.hu

Vántus, Katalin

Budapesti Corvinus Egyetem
E-mail:
katalin.vantus@stud.uni-corvinus.hu

A szerzők a magyar járások COVID-19-halálozási arányaira (elhunytak/fertőzöttek száma) építettek egyszerű statisztikai modellt, a Központi Statisztikai Hivatal (KSH) tájékoztatói adatbázisából és a Nemzeti Egészségbiztosítási Alapkezelő (NEAK) ágyszám-és betegforgalmi kimutatásából származó magyarázó változók segítségével. A felhasznált változók a járások népességének általános egészségi állapotát, illetve a járó- és a fekvőbeteg-ellátás állapotát írják le 2019-ben, a járvány 2020-as kitörése előtti évben. A NEAK adatait a fekvőbeteg-ellátás állapotáról a változók nagy száma miatt klaszterelemzés segítségével vonták be a modellbe. A második és a harmadik COVID-19-hullám nemzetközi összehasonlításban is kedvezőtlen hazai halálozási mutatói miatt indokolt a magyar COVID-19-halálozási arányok területi különbségeinek alapos elemzése. A területi különbségek mögötti jelenségek feltárása segíthet megérteni a magas országos halálozás okait is. A tanulmány újdonsága az eddig végzett kutatások eredményeihez képest, hogy a magyar járások szintjén formális statisztikai modell segítségével vizsgálja a COVID-19-halálozás alakulását, egyszerre három tényezőt – a fekvő- és járóbeteg-ellátás állapotát, valamint a lakosság egészségi állapotát – leíró magyarázó változók függvényében. Az eredmények rávilágítanak a háziorvosi szolgálathoz tartozó ápolók tízezer főre jutó számának és a magyar járások COVID-19-halálozási arányainak összefüggésére: míg azokban a járásokban, ahol a fekvőbeteg-ellátás aktív és egyéb

Kulcsszavak:
COVID-19-halálozás,
területi különbségek,
járó- és fekvőbeteg-ellátás,
ökonometria modell,
Magyarország

* A tanulmány a Nemzeti Népegészségügyi Központ által a COVID-19-járványról közzétett adatokat vizsgálja: a fertőzöttek esetében 2021. február 14-ig, az elhunytak esetében 2021. március 4-ig terjedően.

osztályainak leterheltsége meghaladta az országos átlagot, ott az ápolók száma szignifikánsan negatív hatást gyakorolt a mortalitásra, addig a többi járásban ez a hatás nem figyelhető meg.

COVID-19 mortality rates (number of deaths / infected) of the Hungarian LAU 1 Districts are statistically modelled in this paper, with feature variables describing the general health conditions and the state of in- and outpatient care of the districts. Our data sources are the databases of the Hungarian Central Statistical Office and statements of the National Health Insurance Fund Management (NHIFM). Variables represent the year 2019, as it is the year preceding the global pandemic that started in 2020. Variables from the NHIFM statements describing inpatient care are large in volume, so they are incorporated in our model with the help of clustering. The unfavourable mortality rates of Hungary in international comparison, during the second and third waves of the pandemic highlight the need to investigate the regional differences of the Hungarian COVID-19 mortality indices. Exploring the reasons of regional differences are helping us in understanding the reasons behind the high country-level COVID-19 mortality. Novelty of this paper, compared to previous research, is the creation of a formal statistical model for Hungarian COVID-19 mortality on a district level, using variables describing both the general health conditions and the state of in- and outpatient care of the districts. Our results highlight the connection between the number of nurses at general practitioner services per ten thousand people and the COVID-19 mortality rates at the districts of Hungary. In the districts with a higher than the national average workload at hospitals in active inpatient care and other departments, the number of nurses has a significant negative effect on COVID-19 mortality. This effect cannot be observed in the rest of the districts.

Keywords:

COVID-19 mortality,
regional inequalities,
out- and inpatient care,
econometric model,
Hungary

Beküldve: 2021. július 6.

Elfogadva: 2021. október 6.

Bevezetés

A Vuhan városában 2019 decemberében megjelent új típusú koronavírus (Kincses–Tóth 2020), a SARS-CoV-2 számos területen alapjaiban változtatta meg az emberi élet mindennapjait. A COVID-19-járvány elsődlegesen az emberek egészségi állapotára és emiatt az egészségügyi ellátórendszerre gyakorolt hatást (Pál et al. 2021). Azonban, az elsődleges hatások megfékezésére bevezetett korlátozó intézkedések nyomán a járványnak gazdasági és társadalmi következményei is lettek. Kiemelkedett közülük a turizmus és vendéglátóipari szektorok nagymértékű visszaesése (Boros–Kovalcsik 2021, Czirfusz 2021, Fekete et al. 2021, Remenyik et al. 2021, Kökény–Kiss 2021). A COVID-19 hosszú távú gazdasági és társadalmi következményeinek becslése nem egyszerű és nem is megkerülhető feladat (Dániel et al. 2021). Jelenlegi tapasztalataink alapján hosszú távú válságkezelésre kell felkészülnie a társadalomnak (Boccia et al. 2020, Nyikos et al. 2021, Mitrofanova et al. 2021).

A COVID-19-járvány kapcsán végzett területi kutatások elsődleges fókuszában a vírus halandósági rátájának elemzése és ennek területi különbségei állnak (Parcha et al. 2020, Padula–Davidson 2020, Xie et al. 2021). Említett kutatások a mortalitás területi különbségeit globálisan (Padula–Davidson 2020), egy ország régiói között (Parcha et al. 2020) vagy egy ország konkrét régiójában vizsgálták (Xie et al. 2021). Magyarország COVID-19 közvetlen mortalitási és a járvány alatt mért bármely okú többlethalálzási mutatói több európai szintű összehasonlításban is szerepeltek (Cohen et al. 2021, Bogos et al. 2021, Ferenci 2021, Kovalcsik et al. 2021). E tanulmányok a klasszikus halálzási arányszámokról és a többlethalálzási mutatókról is azt állapították meg, hogy Magyarországon a járvány első hulláma mind a halálzási, mind a fertőzöttségi adatokban alig volt kimutatható, ám a második hullám már súlyosan érintette az országot, a harmadik hullámban viszont Európában a legrosszabb halálzási mutatókkal rendelkező országok között szerepeltünk. Különösen a második és a harmadik hullám kedvezőtlen hazai halálzási mutatói indokolják azok magyarországi területi különbségeinek alapos elemzését. A területi különbségek mögött meghúzódó jelenségek feltárása segíthet megérteni a magas országos szintű halálzás okait is. Ezek ismerete olyan egészségügyi intézkedések bevezetését alapozhatják meg, melyek mérsékelhetik az esetleges későbbi COVID-19-hullámok vagy új járványok halálos áldozatainak számát.

A COVID-19 magyar halálzási mutatóinak országon belüli területi egyenlőtlenségeinek vizsgálata és modellezése ugyanakkor jelenleg még kezdeti szakaszában jár (Páger et al. 2021). Ez azzal magyarázható, hogy míg a hivatalos adatszolgáltatásban a fertőzöttségi adatok csak megyei bontásban, addig a halálzási adatok földrajzi információ nélkül érhetőek el [5]. A mortalitás alakulásának részletesebb regionális elemzésére 2021. május 28-a óta van lehetőség. Ekkor a Nemzeti Népegészségügyi Központ (NNK) hozzáférhetővé tette a COVID-19-ben megfertőzöttek és elhunytak települési szintű számát [1]. Ezen adatforrásra támaszkodva Páger et al. (2021) rávilágít arra, hogy a magyar járások között akár háromszoros különbség is lehetett a

fertőzés okozta halálozási arányban. A COVID-19 okozta magasabb halálozási arányokat az ország azon területein figyelhetjük meg, ahol egyrészt eleve alacsonyabb a születéskor várható átlagos élettartam, másrészt magasabb a krónikus betegek aránya, továbbá az ott élők egészségi állapota is rosszabb az országos átlagnál. Ezek a kezdeti megállapítások is indokolják a COVID-19-halálozási arányszámok mögötti területi különbségek részletes feltárását, a népesség általános egészségi állapota és az egészségügyi ellátórendszer körülményei függvényében, statisztikai-ökonometriai modellek segítségével.

A Páger et al. (2021) tanulmányát megelőző vizsgálatok elsősorban a COVID-19 terjedésének és hatásainak megyei szintű különbségeivel foglalkoztak (Uzzoli et al. 2021). Említett tanulmány az első hullámban kiemeli a fertőzés terjedésének Budapest és Pest megye központúságát, és felhívja a figyelmet a területi koncentráció megszűnésére a második hullám során. Ennek oka a tömeges fertőzések kialakulása a csoportos megbetegedések helyett. A szerzők ezen kívül kiemelik, hogy a második hullámban a fertőzöttek száma az egyes megyékben eltérő időpontban érte el csúcspontját. Az egyre inkább megmutatkozó területi különbségek következtében a járványkezelésben megjelentek a regionális szintű intézkedések is (például számos intézkedés különbözött bizonyos időszakokban a fővárosban, Pest megyében, illetve a többi megyében), ahogy arra utóbbi tanulmány tartalomelemzése is rámutat.

Az egészségügyi ellátórendszer járások szerinti egyenlőtlenségeinek vizsgálatáról is jelentek meg tanulmányok. Közvetlenül a COVID-19-járvány kitörése előtti időszakban Bálint (2021) felhívja a figyelmet a háziorvosi ellátás központi szerepére az egészségügyi alapellátásban. Területi szempontból a tanulmány rámutat arra, hogy a fajlagosan magasabb rendelőben ellátott esetszámmal jellemezhető térségek háziorvosi szolgálatai a már létező betegségekre, egészségügyi problémákra reagálnak, és kevésbé képesek prevencióval hozzájárulni a megbetegedés kialakulásának mérsékléséhez. Ezt az állapotot csak súlyosbította a teljesen új vírus, a COVID-19 okozta megbetegedések ellátási kötelezettségének megjelenése. Ez a feltételezés Páger et al. (2021) tanulmánya alapján igazolhatónak tűnik, hiszen azon járásokban, ahol a lakosság egészségi állapota rosszabb az országos átlagnál, a háziorvosi praxisoknak is az átlagosnál magasabb esetszámot kell ellátniuk.

A járóbeteg-ellátás állapotának fontosságára hívja fel a figyelmet Uzzoli–Kovács (2020) tanulmánya is, ami az ún. komplex egészségügyi távolság indexének alkalmazásával veszi figyelembe a járások gazdasági és társadalmi helyzetét, az egészségügyi intézmények elérhetőségét, hozzáférhetőségét, valamint az adott terület népességének egészségi állapotát. Az eredmények alapján a belső perifériákon és a határ menti területek járásaiban legrosszabb a helyzet. A megyeszékhelyek járásai és a budapesti agglomeráció kedvezőbb helyzetben vannak, ugyanis esetükben jobb az egészségügyi intézmények elérhetősége. A járásban található járóbeteg-szakrendelő léte jelentős hatással van az egészségügyi helyzetre. Ha nincs, vagy csak a járás székhelyén van járóbeteg-szakrendelő, akkor rosszabb az ott élők egészségi állapota. A hivatko-

zott elemzés szerint – a járvány alatt felmerülő szükségletek számításbavételével – figyelmet kell fordítani az ellátásszervezés aktualizálására és területi optimalizálására.

Bálint (2021) és Uzzoli–Kovács (2020) következtetései alapján indokolt, hogy a COVID-19-halálozásokat járási szinten vizsgáló ökonometria modellben mindenképpen szerepeljenek a járóbeteg-ellátás járvány előtti állapotát leíró paraméterek is.

A Koronavírus elleni transzlációs lakosságtámogató akció- és kutatócsoport (The Translational Action and Research Group against Coronavirus – KETLAK) tanulmánya, Gombos et al. (2021) a fekvőbeteg-ellátás megyék közötti különbségeinek fontosságára hívja fel a figyelmet, a COVID-19-járvány miatti halálozás területi különbségeinek vizsgálata során. Említett tanulmány a döntéshozók számára – a járványügyi korlátozások szigorúságának függvényében – különböző kimeneteleket modellezett a járvány alakulásáról. A halálozások számát a szerzők az új fertőzöttek becsült számához, továbbá az intenzív osztályokon elérhető és foglalt ágyakhoz viszonyították. A legjobb forgatókönyv szerint, a járványügyi korlátozások fenntartásával a járvány csúcán elegendő lenne az intenzív osztályon található ágyak száma a COVID-19-betegek ellátására, és 1500-nál kevesebb lenne az összes halálozás. Korlátozások nélkül viszont 3 héten belül nem lenne elegendő az intenzív osztályok ágy száma, és az összes halálozás elérné a 70 ezret. A megyék közötti különbségek elemzése során idézett tanulmány a kórházi kapacitásokban hatalmas különbségeket tárt fel. A modellezés során a legrosszabb forgatókönyvet vizsgálva egyik megye sem rendelkezett elegendő ágykapacitással az intenzív osztályokon. A különbség abban mutatkozott meg, hogy melyik terület meddig lenne képes elérhető ágyat biztosítani a COVID-19-betegek számára. Ahol hamarabb betelnek az intenzív osztályos ágyak, ott várhatóan magasabb lesz az elhalálozás. A járványügyi korlátozások fenntartásával viszont elegendő lenne a kórházi kapacitás, a megyék közötti különbségek ellenére is. A hivatkozott tanulmány megállapításai azt támasztják alá, hogy a COVID-19-halálozás területi különbségeinek modellezése során a fekvőbeteg-ellátás járvány előtti állapotát és kapacitását leíró változók alkalmazása elengedhetetlen.

Mivel a Nemzeti Népegészségügyi Központ (NNK) 2021. május 28-án elérhetővé tette a magyar COVID-19 fertőzöttek és elhunytak települési szintű számát, így már járási szinten kiszámítható a fertőzésben elhunytak aránya (elhunytak/fertőzöttek száma). Ehhez a változóhoz hozzárendelhetők a [2] és [3] adatbázisok ágyszám- és betegforgalmi kimutatása alapján a járások népességének általános egészségi állapotát, valamint járó- és fekvőbeteg-ellátásának legfontosabb jellemzőit leíró változók a COVID-19-járványt közvetlenül megelőző, 2019. évből.

Jelen tanulmány célja, hogy lineáris ökonometriai modellel elemzi a járások COVID-19-halálozási arányainak területi különbségeit meghatározó tényezőket. A dolgozat a járások népességének általános egészségi jellemzői és a járóbeteg-ellátás alapvető mutatószámainak hatása mellett elsősorban a fekvőbeteg-ellátás COVID-19-járvány előtti állapotának a COVID-19-halálozási arányra gyakorolt hatását vizsgálja. A fekvőbeteg-ellátás jellemzőit leíró 25 változót klaszterelemzés segítségével

építjük be a modellbe. Vizsgáljuk továbbá az egyéb mutatók fekvőbeteg-ellátás szerinti regionális klaszterekkel vett együttes (interakciós) hatásait is a COVID-19-halálozási arányra. A tanulmány újdonsága az előbbieken ismertetett kutatásokhoz képest, hogy formális ökonometriai modell segítségével járási szinten elemzi a COVID-19-halálozás alakulását az egyszerre három tényezőt – a fekvő- és járóbeteg-ellátás állapotát, valamint a lakosság egészségi állapotát – leíró változók függvényében.

Adatok és módszerek

A dolgozatban az NNK által 2021. május 28-án elérhetővé tett magyar település szintű COVID-19-járványadatokról indulunk ki [1]. A fertőzöttek számának 2021. február 14-ig, az elhunytak számának 2021. március 4-ig terjedő adataiból kiszámítottuk a járási szintű halálozási arányokat (elhunytak/fertőzöttek száma, %). A két adatsor nem teljesen ugyanarra az időszakra vonatkozik, ám mivel a nemzetközi tapasztalatok alapján a betegség lefolyása hozzávetőlegesen két hét, így az adatok időhorizontjának 18 napos eltérése még elfogadható. Ezen kívül a járási szintű aggregálás kiküszöböli az eltérő időhorizont és az alacsony lélekszám miatt 8 településen megfigyelt 1 vagy 2 halálozást. Az elemzésben Budapest önmagában, aggregált adatokkal szerepel, emiatt a modellezés során folyamatosan ellenőrizzük, hogy kiugró értékei mennyire befolyásolják a számításokat. Így összességében 175 megfigyelési egységet vizsgálunk ($n=175$). Megjegyzendő, hogy érdemes lenne a többlethalálozási adatok regionális különbségeit is elemezni, hiszen a járványhelyzet miatt a nem megfelelően ellátott egyéb betegségek miatt szintén emelkedhetett a halálozás (Ferencsi 2021). Azonban a többlethalálozási mutatók számításához szükséges időbeli részletezettségben a halálozások száma nem érhető el járási szintű bontásban.

A COVID-19-halálozási arányokat először leíró statisztikai eszközökkel vizsgáljuk meg. A halálozási arányok járások szerinti eloszlásának alakulását az átlag, a szórási, a medián, a minimum és a maximum mutatókkal jellemezzük, majd az eloszlásnak a normális eloszláshoz képest a ferdeségét és a csúcosságát is elemezzük, az α_3 és α_4 alakmutatók¹ segítségével. A halálozási arányok eloszlását hisztogram és dobozábra segítségével jelenítjük meg. A dobozábra pontokkal jelöli a Tukey-féle kerítések alapján kilógónak számító értékeket.² Az alkalmazott leíró statisztikai módszerekről részletes áttekintést nyújt például Hunyadi–Vita (2006).

¹ Az α_3 ferdeségi mutató közelítőleg 0 értéket vesz fel szimmetrikus eloszlás esetén, míg pozitív értéket jobbra, negatív értéket balra elnyúló eloszlás esetén. Az α_4 csúcossági mutató közelítőleg 0 értéket vesz fel a normális eloszlásnak megfelelő csúcosság esetén, míg pozitív értéket a normálisnál csúcsosabb, negatív értéket a normálisnál lapultabb eloszlás esetén.

² A Tukey-féle alsó kerítés az alsó kvartilis $-1,5$ *interkvartilis terjedelem, míg a felső kerítés a felső kvartilis $+1,5$ *interkvartilis terjedelem módon adott. Amennyiben egy megfigyelési érték kisebb/nagyobb, mint a Tukey-féle alsó/felső kerítés, akkor az kilógónak minősül, mivel a megfigyelések középső 50%-hoz képest túl alacsonyan/magasan helyezkedik el.

Az általános nemzetközi tapasztalatok és az előzőekben ismertetett korábbi kutatások alapján a magyar járások COVID-19-halálozási arányait az 1. táblázatban található változókkal magyarázzuk. A táblázat változói 2019-re értendők, mivel a különböző járások jellemzőit a magyarországi COVID-19-járvány 2020. márciusi kitörését közvetlenül megelőző időpontban vizsgáljuk annak érdekében, hogy megtudjuk: a járások járvány előtti adottságai milyen hatással voltak a COVID-19-halálozási arányokra. A változók eloszlását a Mellékletben az M1. ábra mutatja be.

1. táblázat

A járások COVID-19-halálozási arányát magyarázó változók
Variables interpreting COVID-19 mortality rates at districts

Változó neve	Leírás
Háziorvosok	Háziorvosok száma tízezer főre, 2019
Apolok	Háziorvosi szolgálathoz tartozó szakápolók/ápolók száma tízezer főre, 2019
Munkanelküliség	Nyilvántartott álláskeresők száma tízezer főre, 2019
Nok65Felett	Lakónépességből a 65 éves és idősebb nők aránya (%), 2019. december 31.
Ferfiak65Felett	Lakónépességből a 65 éves és idősebb férfiak aránya (%), 2019. december 31.

Forrás: [2] alapján saját szerkesztés.

A járóbeteg-ellátás elérhetőségét két változóval, a háziorvosok és a háziorvosi szolgálathoz tartozó szakápolók/ápolók tízezer főre jutó számával mérjük. Nemzetközi tapasztalat alapján a COVID-19 leggyakrabban a 65 éves és idősebb népesség körében halálos kimenetelű (Bonanad et al. 2020, Kang–Jung 2020), ezért szerepeltetjük a járás 65 éves és idősebb férfi, valamint női népességének arányát is a változók között. A járási népesség általános egészségi állapotának jellemzéséhez egy indikátorváltozót használunk, az álláskeresők tízezer főre jutó számát. Több kutatás (Bíró–Elek 2020, Ruhm 2016, Kuhn et al. 2009) is megerősíti azt, hogy a magas munkanélküliség regionálisan szorosan együtt mozog a születéskor várható átlagos élettartammal és az egészségi állapotot leíró egyéb mutatókkal.

A 2. táblázatban található változók segítségével először az (1) képlet szerint lineáris modellel magyarázzuk a magyar járások COVID-19-halálozási arányainak járások közötti szóródását.

$$\ln COVIDHalal_i = \beta_0 + \beta_{Háziorvosok} \cdot Háziorvosok_i + \beta_{Apolok} \cdot Apolok_i + \beta_{Mnk} \cdot \ln Munkanelkuliseg_i + \beta_{Nok65} \cdot Nok65Felett_i + \beta_{Ferfiak65} \cdot Ferfiak65Felett_i + \varepsilon_i \quad (1)$$

Az (1) modellben a Melléklet M1. ábra alapján a *COVIDHalal* és *Munkanelkuliseg* változókat jobbra elnyúló eloszlásuk miatt logaritmáljuk, hogy kapcsolatuk egymással és a *COVIDHalal* változóval, valamint a többi vizsgált változóval lineáris modellel jól leírható legyen. A többi változó közel szimmetrikus eloszlása miatt egyéb transzformáció nem indokolt. Az (1) modell paramétereit klasszikus legkisebb négyzetek módszerével (LNM) becsüljük. Az LNM-becslés alkalmazásához ellenőrizni

kell annak feltételrendszerét. Ezen feltételek közül a modell hibatagjának normalitását Jarque-Bera próbával, homoszkedaszticitását White próbával ellenőrizzük, a multikollinearitás mértékét variancia inflációs faktorokkal (VIF) vizsgáljuk minden változóra, Wooldridge (2016) alapján.

Kutatásunk második lépésében megkíséreljük kibővíteni az (1) modellt, hogy az a járóbeteg-ellátás jellemzői (házi orvosok és a hozzájuk tartozó ápolók tízezer főre jutó száma) mellett az adott járás kórházi ellátásának viszonyait is tartalmazza. Gombos et al. (2021) alapján feltételezhetjük, hogy a COVID-19 járásonkénti halálozási arányait a kórházak felkészültsége is befolyásolta. Ennek méréséhez a [3] adatbázis 2019. évi kórházi ágyszám- és betegforgalmi kimutatásának adatait használjuk fel. Hasonlóan az (1) modellben eddig alkalmazott magyarázó változókhoz, a kórházi ellátást leíró változókat is a magyarországi járvány kitörését közvetlenül megelőző évben, 2019-ben vizsgáljuk annak érdekében, hogy a kórházi ellátás járvány előtti állapotának hatását kimutathassuk a halálozási arányokra. A [3] adatbázisból a kórházi ellátást jellemző változók regionális szinten megyei bontásban nyerhetők ki, így a járásokhoz az adatokat megyéjükön keresztül rendeltük hozzá. Budapestet külön „megyeként” szerepeltetjük. A felhasznált változók listáját a 2. táblázat tartalmazza.

2. táblázat

A fekvőbeteg-ellátás mérésére szolgáló változók listája, 2019

List of variables used to measure the state of inpatient care procured, 2019

Sorszám	Változó
1.	Összes kórházi ágyak átlagos száma (tízezer lakosra)
2.	Működő kórházi ágyak átlagos száma (tízezer lakosra)
3.	Egynapos ellátási esetek száma (tízezer lakosra)
4.	Ápolás átlagos időtartama (nap)
5.	Osztályról eltávozott betegek aránya az osztályról összesen elbocsátott betegek számához képest
6.	Osztályról áthelyezettek aránya az osztályról összesen elbocsátott betegek számához képest
7.	Halálozási arány (az osztályon elhunytak száma osztva az osztályról összesen elbocsátott betegek számával)
8.	Ágykihasználtság (működő kórházi ágyak átlagos száma osztva az összes kórházi ágyak átlagos számával)
9.	Teljesített ápolási napok aránya (teljesített ápolási napok száma osztva a teljesíthető ápolási napok számával)

Forrás: [3] alapján saját szerkesztés.

Az elemzés során az adott változó aktív, krónikus és egyéb (újszülött és nappali kórházi) ellátásra vonatkozó mutatója külön változóba került (például a működő kórházi ágyak átlagos számára vonatkozik egy aktív, egy krónikus és egy egyéb ellátási változó is). Ez a felbontás azért volt szükséges, mivel ez a 3 fekvőbeteg-ellátási forma jellemzőiben különbözik egymástól. A [3] adatbázisból összességében ezzel

9 x 3 oszlop származik, de mivel az egynapos ellátási esetek száma változó, valamint a krónikus és egyéb osztályok esetében nem nyújt pluszinformációt (ugyanis csak nullák szerepelnek ebben a két oszlopban), így ez a két változó elhagyható. Ezzel a [3] kimutatásából $(9 \times 3) - 2 = 25$ potenciális magyarázó változót használtunk fel.

A már 5 magyarázó változóval rendelkező (1) modellnek a [3] adatbázisból származó 25 változóval történő kibővítése 30 magyarázó változót jelentene, ami már megközelíti a megfigyelések számának ötödét (35), így a modell takarékoságának szem előtt tartásával nem célszerű mind a 25 változót beépíteni a modellbe. A változók továbbá csak megyei szinten állnak rendelkezésre, így azok járási szintű vizsgálata elég kis értékkészletet eredményezne: minden változó esetében 20 értéket a 175 megfigyelésre.

Emiatt a fekvőbeteg-ellátást leíró 25 változó számának csökkentéséhez először főkomponens-elemzést végzünk a megyék szintjén, az egymással szorosan korreláló változók körében, ahol a főkomponensek előállítását követően az 1 fölötti sajátértékkel rendelkező főkomponenseket tartottuk meg, Bro–Smilde (2014) ajánlása alapján. A főkomponensek és az eredeti változók közötti korrelációk könnyebb olvashatóságának, és így a megőrzött komponensek könnyebb értelmezhetőségének érdekében Varimax rotációt végzünk (Lawley–Maxwell 1971). Ezek után, a megőrzött főkomponenseket visszaileszítjük a főkomponens-elemzésbe nem bevont, fekvőbeteg-ellátást leíró változók mellé. Az így redukált változóhalmazt 0 átlagúra és 1 szórásúra transzformáljuk, az eltérő mértékegységek hatásának kiküszöbölése érdekében, majd k-közép és hierarchikus klaszterelemzést végzünk rajtuk, továbbra is a megyék szintjén.

Először a hierarchikus klaszterelemzést hajtjuk végre, mivel az eredmény dendrogramja alapján következtethetünk az optimális klaszterszámra (Kovács 2014). Mivel a klaszterezéshez folytonos változókat használunk, így az egyedek közötti távolságot euklideszi távolsággal mérjük (Kovács 2014). A klaszterek távolságát Ward-módszerrel határozzuk meg, mivel ez utóbbi eljárás kiegyenlített elemszámú klaszterek kialakítására törekszik (Murtagh–Legendre 2014). A dendrogram alapján nyert optimális klaszterszámmal k-közép klaszterezést is futtatunk. A k-közép módszer előnye, hogy a végső klaszterközépek alapján a klaszterek főbb jellemzői meghatározhatók. Az optimális klaszterszám ellenőrzéséhez a sziluett módszert alkalmaztuk (Rousseeuw 1987, Szüle 2019). Végül a két eljárás konzisztenciáját a Cramer-féle V mutatóval ellenőrizzük (Kovács 2014).

Mivel a k-közép eljárásból nyert klaszterek az eljárás által megadott klaszterközépek segítségével könnyen értelmezhetők, így a vizsgált magyar járások megyéjének k-közép eljárás szerinti klasztertagsággal bővítjük az (1) modell magyarázó változóinak körét, valamint vizsgáljuk a potenciális interakciós hatásokat is. A hierarchikus klaszterezés alkalmazásának célja elsősorban az eredmények stabilitásának ellenőrzése. Ezzel a módszerrel viszonylag kevés új változó bevonásával kimutatható az egyes járások fekvőbeteg-ellátás állapotának hatása a járás COVID-19-halálozási arányára.

A szükséges adatfeldolgozást és elemzéseket az R nyelv 4.1.0 verziójával végeztük. A *base* és *stats* könyvtáron túl a regressziós tesztek elvégzéséhez a *car*, *tseries*, *lmtest* és *skedastic*, a klaszterelemzés során a *factoextra* és *NbClust* könyvtárakat használtuk.

Eredmények

Az Adatok és módszerek fejezet alapján először az eredményváltozónk, a COVID-19-halálzási arány leíró statisztikai elemzését végezzük el. Ennek eredményei alapján A kezdeti regressziósmodell-építés eredményei című alfejezetben elkészítjük az (1) modell paramétereinek LNM-becslését. Az eredmények függvényében szűkítjük a modellt, és a szignifikáns együtthatók alapján bemutatjuk a COVID-19-halálzási arányok területi különbségei mögött álló tényezőket. A Klaszterezés eredményei című alfejezetben először a megyei szintű, fekvőbeteg-ellátást jellemző [3] adatbázisból származó 2. táblázatban szereplő változókon elvégzett főkomponens-elemzés eredményeit ismertetjük. A főkomponens-elemzés segítségével szűkített változómalmazon áttekintjük a hierarchikus klaszterelemzés eredményeit. Az eljárás dendrogramja alapján megállapítjuk az optimális klaszterszámot, melynek segítségével k-közép klaszterelemzést hajtunk végre, majd ellenőrizzük a két eljárás által javasolt klaszterek konzisztenciáját. A k-közép eljárás eredményeül kapott klaszterek jelentés tartalmát az algoritmus által szolgáltatott klaszterközépek segítségével ismertetjük. A fekvőbeteg-ellátás szerinti klaszterek beépítése a regressziós modellbe című alfejezet elején egyszerűbb, leíró statisztikai eszközökkel mutatjuk be fekvőbeteg-ellátást leíró klaszterek kapcsolatát a COVID-19-halálzási aránnyal. Az eredményeket felhasználva építjük be a fekvőbeteg-ellátás szerinti klasztertagságot a szűkített regressziós modellbe, tesztelve az egyéb magyarázó változókkal vett interakciós hatásokat is. A megvizsgált bővített modellek közül kiválasztjuk a megfigyelt adatokra legponosabban illeszkedőt, és az együtthatói alapján újabb, a COVID-19-halálzási arányok területi különbségei mögött álló tényezőket mutatunk be. Ezekben az új tényezőkben megjelenik a fekvőbeteg-ellátás járvány előtti állapotának önálló, vagy más változókkal vett együttes (interakciós) hatása is.

A COVID-19-halálzási arány leíró statisztikai elemzése

Elemzésünk első fázisában a magyar járások COVID-19-halálzási arányainak alakulását az Adatok és módszerek fejezetben bemutatott leíró statisztikai eszközökkel vizsgáltuk meg. A COVID-19-halálzási arány leíró statisztikai elemzésének eredményeit a 3. táblázat és az 1. ábra tartalmazza.

3. táblázat

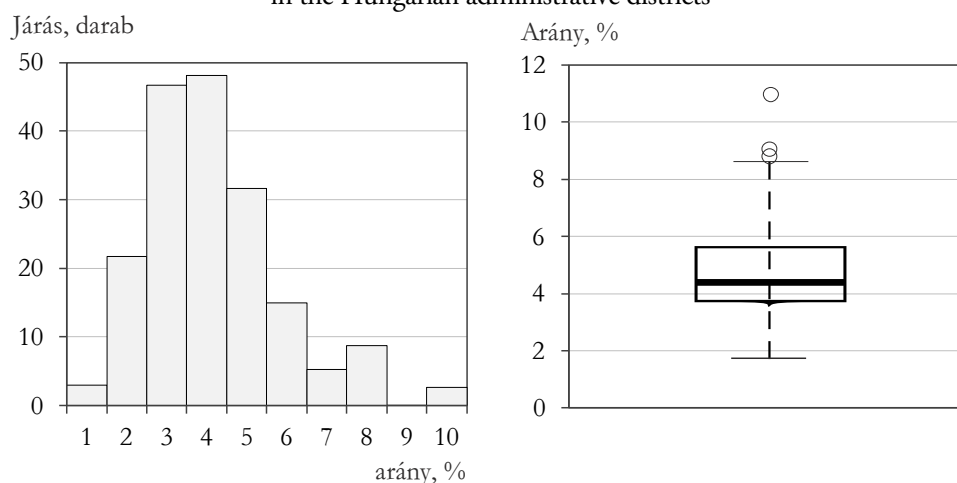
A magyar járások COVID-19-halálozási arányainak leíró statisztikái
 Descriptive statistics of the COVID-19 mortality rates
 in the Hungarian administrative districts

	Átlag	Szórás	Medián	Min.	Max.	Ferdesség (α_3)	Csúcsosság (α_4)
COVID-19 halálozási arány, %	4,60	1,54	4,28	1,74	10,70	0,99	1,18

Forrás: [1] alapján saját szerkesztés.

1. ábra

A magyar járások COVID-19-halálozási arányainak hisztogramja és dobozábrája
 Histogram and box plot of the COVID-19 mortality rates
 in the Hungarian administrative districts



Forrás: [1] alapján saját szerkesztés.


A leíró statisztikai elemzés alapján megállapíthatjuk, hogy a változó jobbra elnyúló eloszlása ellenére extrém módon kilógó értéket – a Szikszói járás (10,7%) kivételével – nem tartalmaz. A járások középső 50%-ában a halálozási arány 3,6 és 5,5% közötti. A Szikszói járást követő 4 (Encsi – 8,69, Kunszentmiklósi – 8,68, Pétervársárai – 8,49, Jánoshalmi – 8,28%) legmagasabb halálozási arányú járás esetén az arányok 1 százalékponttal sem haladják meg a felső Tukey-féle kerítés értékét (8,27%). A 3. táblázat alapján a halálozási arány átlaga és mediánja is csak 0,32 százalékponttal különbözik, a relatív szórás 33,5%. Az alakmutatók is megerősítik az eddigi megfigyeléseinket: az aszimmetria (α_3) és a csúcsosság (α_4) mutatója is enyhén pozitív értéket vesz fel, tehát a járások halálozási arányainak eloszlása a normális eloszláshoz képest jobbra elnyúló és csúcsos, de nem extrém mértékben. A legmagasabb (Szikszói járás) és legalacsonyabb (Kapunvári járás) halálozási arány közötti különbség körülbelül hatszoros (6,149).

A 2. ábrán megfigyelhetjük, hogy a Tukey-féle felső kerítés értéke feletti halálzási aránnyal rendelkező járások területileg nem koncentrálnak: Északkelet-Magyarországon, Közép-Magyarországon és a Dunántúlon is található 8,27% feletti halálzási arányú járások. Ellenben az alsó decilis (2,86%) alatti halálzási arányú járások főleg Északnyugat-Magyarországra és Pest megyére koncentrálnak.

2. ábra

A magyar járások COVID-19-halálzási arányainak területi eloszlása

Distribution of COVID-19 mortality rates
between Hungarian administrative districts



Forrás: [1] alapján saját szerkesztés.

A leíró statisztikai elemzések alapján (1. és 2. ábra, 1. táblázat) a járások halálzási arányaiban olyan szintűek a különbségek, hogy azokat érdemes különböző változók segítségével magyarázni, amit mi először az (1) modell segítségével teszünk meg.

A kezdeti regressziósmodell-építés eredményei

Az (1) modell paramétereinek LNM-becslését és a modelldiagnosztikai mutatószámokat a 4. táblázat „Teljes modell” oszlopai tartalmazzák. A Melléklet M1. ábrája szerint extrém módon kiugró értékek egyik modellben szereplő változóban sem azonosíthatók, így nem kell attól tartanunk, hogy ezek az értékek befolyásolnák az LNM-becslés eredményét.

4. táblázat

Az LNM-beccsléssel előállított lineáris modellek paraméterei és legfontosabb diagnosztikai mutatói
Parameters and significant diagnostic indices for the basic linear models estimated by OLS

Y: ln(COVIDHalal)	Teljes modell			Szűkített modell		
	koefficiens	p-érték	VIF	koefficiens	p-érték	VIF
Konstans	-0,451	0,085	–	-0,524	0,034	–
Háziorvosok	0,010	0,741	1,620	–	–	–
Apolok	-0,030	0,126	1,838	-0,028	0,120	1,566
ln(Munkanélküliség)	0,305	0,000	1,642	0,320	0,000	1,396
Nok65Felett	0,057	0,077	6,188	0,031	0,028	1,182
Ferfiak65Felett	-0,045	0,344	6,485	–	–	–
R-négyzet	0,3537			0,3501		
Korrigált R-négyzet	0,3347			0,3388		
AIC	39,4233			36,3878		
BIC	61,6167			52,2403		
White négyzetekkel és interakciókkal (p-érték)	0,6350			0,4030		
Jarque-Bera (p-érték)	0,4043			0,4182		

Megjegyzés: A táblázatban alkalmazott rövidítések kifejtése a következő: VIF = variancia inflációs faktor; AIC = Akaike információs kritérium; BIC = Bayes–Swarz információs kritérium. A modellek kiértékeléséhez alkalmazott mutatók és az elvégzett hipotézisvizsgálatok p-értékei mögött álló statisztikai próbák részletes leírását lásd Wooldridge (2016).

Forrás: [1–3] alapján saját szerkesztés.

A teljes modell az R-négyzet mutató alapján közepes magyarázó erővel rendelkezik (35,37%). A modell hibatagja a Jarque-Bera próba p-értéke alapján minden szokásos szignifikanciaszinten (1–10%) normális eloszlásúnak tekinthető, míg a White próba alapján minden szokásos szignifikanciaszinten homoszkedasztikusnak is bizonyul. Tehát, a parciális t-próbák p-értékei értelmezhetők. Míg a parciális t-próbák alapján a *Háziorvosok*, *Apolok* és *Ferfiak65Felett* változók nem szignifikánsak a szokásos szignifikanciaszinten, addig a *Nok65Felett* változó csak 10%-os szignifikanciaszinten szignifikáns.

A *Ferfiak65Felett* változó magas t-próba szerinti p-értékét magyarázhatja a káros/zavaró multikollinearitása (5–10 közötti VIF értéke) a *Nok65Felett* változóval. Érdekes lehet továbbá együtthatójának negatív előjele is. Mindezen eredmények együttesen azt mutatják, hogy változatlan munkanélküliség, a háziorvosok és az ápolók tízezer főre jutó száma, valamint a 65 éves és idősebb női népesség aránya mellett a 65 éves és idősebb férfiak arányának növekedése a járás népességében várhatóan a COVID-19-halálozási arány csökkenését vonja maga után. Noha ez a hatás nem szignifikáns és első körben ellentmond annak a nemzetközi tapasztalatnak, amely szerint a COVID-19-fertőzés elsősorban az idősebb korosztályokban


halálos kimenetelű (Bonanad et al. 2020, Kang–Jung 2020). A jelenségre magyarázatot adhatnak a magyar férfi és női halandósági táblákban mutatkozó nagy különbségek. A [4] adatbázis 2017. évi adatai alapján az 45 évesen várható átlagos élettartam Magyarországon 29,2 év a férfiak és 35,3 év a nők esetében. Ez a 6,1 éves különbség 65 éves korra 3,9 évre mérséklődik (nők: 18,3 év, férfiak: 14,4 év). Ez arra enged következtetni, hogy 45 és 65 éves koruk között a rosszabb egészségi állapotban lévő férfiak jelentős hányada hunyt el. Így azok, akik megélik a 65 éves kort már erősebb immunrendszerrel és feltehetően kevesebb COVID-19-halálozás szempontjából kockázatos alapterettséggel (Banerjee et al. 2020, Mohamed et al. 2020) rendelkezhetnek, így a COVID-19-cel szemben is ellenállóbbak. Emiatt logikus lehet, hogy a COVID-19-halálozási arányra a *Ferfiak65Felett* változó negatív, de nem szignifikáns marginális hatást gyakorol. A *Nok65Felett* változó 10%-on szignifikáns, pozitív marginális hatása tükrözi azt a várakozást, hogy a COVID-19-halálozás az időskorú népességben magas. Mivel a magyar népességben a nők közül többen élik meg a 65 éves kort, így feltehető, hogy közöttük nagyobb arányban találhatóak gyengébb immunrendszerrel és több alapterettséggel rendelkezők. Hiszen, ők nem hunytak el 65 éves korukig, mint a hasonló egészségi állapotú férfiak.

A következtetést alátámasztja, hogy az [5] 2021. június 25-ei adatai alapján a férfiak esetében a COVID-19-ben elhunytak életkora jellemzően alacsonyabb, mint a nők esetében (3. ábra).

3. ábra

A magyarországi COVID-19 miatt elhunytak életkorának dobozábrája, 2021. június 25.

Box plot for the age distribution of the Hungarian COVID-19 deceased, 25 June 2021



Forrás: [5] alapján saját szerkesztés.

A 3. ábrán szembevetőd, hogy a nők halálozási életkorának alsó kvartilise (70 év) mindössze 2 évvel alacsonyabb, mint a férfiak halálozási életkorának mediánja (72 év), továbbá a nők halálozási mediánéletkora (79 év) lényegében megegyezik a férfiak halálozási életkorának felső kvartilisével (80 év). A 3. ábra és a *Ferfiak65Felett* változó inszignifikanciája (4. táblázat) arra enged következtetni, hogy a 65 éves és idősebb életkort csak a jobb általános egészségi állapotban lévő férfiak élnek meg, és körükben ebből adódóan lényegesen kisebb lehet a COVID-19 miatti halálozási kockázatot szignifikánsan növelő alapbetegségben érintettek aránya.

A *Háziorvosok* változó magas t-próba szerinti p-értéke nem magyarázható a multikollinearitással, és az együtttható pozitív előjelére sem adható könnyen logikus magyarázat.³ Ez arra enged következtetni, hogy a háziorvosok tízezer főre jutó számának nincs önálló marginális hatása a COVID-19-halálozási arányok alakulására. Ellenben az *Ápolók* változó együttthatójának előjele a várakozásoknak megfelelően negatív: változatlan munkanélküliség, a háziorvosok tízezer főre jutó száma, 65 éves és idősebb női és férfi népesség mellett az ápolók tízezer főre jutó számának növekedése várhatóan csökkenti a COVID-19-halálozási arányt. A változó és a t-próba szerinti p-értéke is csak 2,6 százalékponttal haladja meg a legnagyobb szokásos, 10%-os szignifikanciaszintet, így nem feltétlenül érdemes a változó hatását egyértelműen nem szignifikánsnak venni. A járóbeteg-ellátás méretét leíró két változó eltérő marginális hatásai egyrészt azzal magyarázhatók, hogy az ápolók számának járások szerinti eloszlása egyenlőtlenebb, mint a háziorvosoké. Az *Ápolók* változó terjedelme 7,2 és relatív szórása 21,6%. Ez a két mutató a *Háziorvosok* változóra rendre 5,7 és 17,4%. Másrészt, a jelenség oka lehet, hogy a háziorvosi ellátásban inkább a szakápolók végzik a betegellátás mindennapi feladatait (NNK 2019), így a COVID-19-járvány miatt megnövekedett terhelés is elsősorban őket érintette. Természetesen nem zárható ki az sem, hogy ez a jelenség egy, jelen kutatásban nem megfigyelt, kihagyott változó okozta torzítással magyarázható. Ugyanakkor fontos megjegyeznünk, hogy az eredményeink összhangban vannak Padula–Davidson (2020) következtetéseivel. A kutatás több országot vizsgálva azt mutatta ki, hogy a magasabb népességarányos ápolószám várhatóan csökkenti a COVID-19-halálozást. Mindezek alapján a fekvőbeteg-ellátásban a járások közötti különbségek közül a szakápolók tízezer főre jutó számában megfigyelhető egyenlőtlenségek mérséklése sürgősebb feladatnak tűnik, mint a háziorvosok tízezer főre jutó számának kiegyenlítése.

A modell egyetlen 1%-on is szignifikáns változója a *Munkanélküliség* logaritmusáé. Együttthatója parciális rugalmasságként értelmezhető: változatlan 65 éves és idősebb férfi-nő arányok, valamint tízezer főre jutó ápoló- és háziorvosszám mellett, ha egy járásban 1%-kal nő az álláskeresők tízezer főre jutó száma, akkor a COVID-19-halálozási arány várhatóan 0,3%-kal nő. A pozitív hatás alapján megerősíthető az a várakozás, hogy a munkanélküliség a járás népességének egészségi állapotára vonat-

³ Hiszen a pozitív előjel a COVID-19-halálozási arány növekedésére utalhat, magas tízezer főre jutó háziorvosszám esetén.

kozó indikátorként használható. A változó alkalmazásával a modellbe be tudjuk építeni azt a leíró statisztikai elemzés 2. ábráján látható, valamint Páger et al. (2021) által is kiemelt jelenséget, mely szerint a magas COVID-19-halálozási arányok azokban a járásokban jellemzők, ahol eleve alacsonyabb a születéskor várható átlagos élettartam, magasabb a krónikus betegségek aránya, továbbá az ott élők egészségi állapota is rosszabb az országos átlagnál.

A változók együttthatójának előjelét és szignifikanciáját leíró p-érték figyelembevételével az (1) modellből elhagyjuk a két legerősebben nem szignifikáns változót (*Háziorvosok* és *Ferfiak65Felett*). E két változó esetében a magas p-érték mögött vagy jól értelmezhető hatás áll (*Ferfiak65Felett* esete), vagy a p-érték kifejezetten magas és a becsült együtttható előjele sem logikus (*Háziorvosok* esete). A változók elhagyásával minden változószelekciós mutatószám (korrigált R-négyzet, AIC, BIC) értéke javult (4. táblázat szűkített modell oszlopai). A szűkített modell hibatagjára vonatkozó normalitás- és heteroszkedaszticitásvizsgálatok eredményeiből levonható következtetések nem változtak. Megkíséreltük elhagyni az *Apolok* változót is, de ez a lépés a korrigált R-négyzet (0,3333) és AIC értékeket rontotta (36,8723), a BIC-et (49,5546) pedig csak kismértékben javította. Továbbá, előjele alapján a változó marginális hatása a COVID-19-halálozásra logikus, és p-értéke a szűkített modellben csak 2 százalékponttal marad el a legmagasabb szokásos szignifikanciaszinttől (10%). A 4. táblázat szűkített modelljének alkalmazása tehát nem változtatja meg a korábbi megállapításainkat, hanem a modellszelekciós kritériumok alapján megerősíti azokat: a háziorvosok tízezer főre jutó számának és a 65 éves és idősebb férfiak arányának nincs szignifikáns marginális hatása a járások COVID-19-halálozási arányaira. Míg a járások magasabb munkanélkülisége, valamint a 65 éves és idősebb nők népességen belüli nagyobb aránya növeli a COVID-19-halálozási arányt, addig háziorvosi szolgálatban dolgozó ápolók tízezer főre jutó magasabb száma marginálisan csökkenti azt.

Mindezek alapján a 4. táblázat szűkített modelljével dolgozunk tovább. Dummy változók segítségével ebbe vesszük bele a járások fekvőbeteg-ellátás mutatói alapján kialakult klasztertagságát.

A klaszterezés eredményei

Az Adatok és módszerek fejezet leírása alapján először a szorosan korreláló [3] adatbázisból származó változókon főkomponens-elemzést végeztünk. Az elemzésbe bevont változók körét a megyék kórházi ágyszám- és betegforgalmi kimutatásából nyert változóinak és egyéb egészségügyi ellátást leíró mutatóinak, valamint az 1-nél nagyobb sajátértékű főkomponenseinek [Internetes mellékletben](#) található rotált korrelációmátrixa alapján határoztuk meg: az egymással szorosan korreláló változókat vontuk össze főkomponensekbe. A Varimax rotáció alkalmazása után az 1-nél nagyobb sajátértékű főkomponensek és az eredeti változók (szintén az Internetes mellékletben található) korrelációi alapján egyértelműen meghatározható volt, hogy

mely főkomponens, mely eredeti változókkal áll szoros kapcsolatban, így megkönnyítve az elnevezésüket. A 4. és 8. rotált főkomponens egy-egy változóval korrelál erősen, ezáltal nem tudunk több változót összevonni. A továbbiakban használt többi rotált főkomponens és a velük erősen korreláló változókat az 5. táblázatban mutatjuk be.

5. táblázat

A rotált főkomponensekben összevont a fekvőbeteg-ellátást leíró változók

List of new variables describing the state of inpatient care based on the rotated principal components

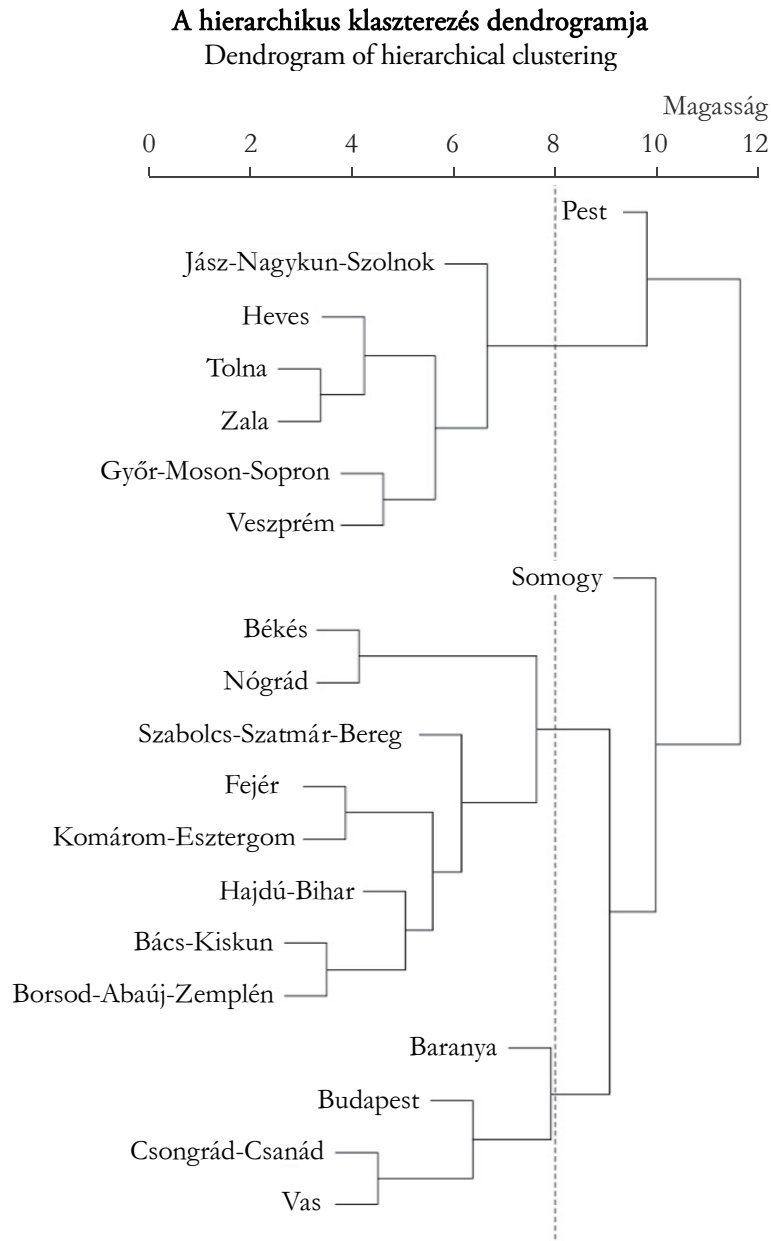
Rotált főkomponensek	Adott főkomponenssel erősen korreláló változók
PC1 = aktív ellátásban lévő ágyak	Összes kórházi ágyak átlagos száma (aktív) Működő kórházi ágyak átlagos száma (aktív)
PC2 = krónikus ellátásban lévő ágyak	Összes kórházi ágyak átlagos száma (krónikus) Működő kórházi ágyak átlagos száma (krónikus)
PC3 = aktív osztályok betegforgalma	Ápolás átlagos időtartama (aktív) Osztályról ténylegesen elbocsátottak aránya (aktív) Osztályról áthelyezettek aránya (aktív)
PC4 = aktív osztályok leterheltsége	Ágykihasználtság (aktív) Teljesített ápolási napok aránya (aktív)
PC5 = egyéb ellátásban lévő ágyak	Összes kórházi ágyak átlagos száma (egyéb) Működő kórházi ágyak átlagos száma (egyéb)
PC6 = krónikus osztályok leterheltsége	Ágykihasználtság (krónikus) Teljesített ápolási napok aránya (krónikus)

Forrás: [3] alapján saját szerkesztés.

A főkomponens-elemzés után az adatbázis összesen $25 - 13 + 6 = 18$ változót tartalmaz, amelyeket 0 átlagúra és 1 szórásúra transzformáltunk. A következőkben a bemutatott két módszer szerint elvégeztük a megyék egészségügyi ellátottság szerinti klaszterelemzését, a 18 változó alapján.

Elsőként hierarchikus klaszterezést alkalmaztunk. A hierarchikus klaszterezés dendrogramján (4. ábra) jól láthatóan elkülönül 5 klaszter, így a $k = 5$ -öt választottuk optimális klaszterszámmá.

4. ábra



Forrás: [3] alapján saját szerkesztés.

A belső eltérés-négyzetösszegek különböző klaszterszámok szerinti ellenőrzése egyik klaszterszám esetén sem mutatott kiugró változás (Melléklet M2. ábra). A hierarchikus klaszterezés eredményeképpen két 1, egy 4, egy 6 és egy 8 tagú klasztert


hoztunk létre. Az első klaszterbe egyedül Pest megye, a másodikba pedig egyedül Somogy megye került. Csongrád-Csanád, Baranya és Vas megye, valamint Budapest alkotják a harmadik klasztert. A negyedik klaszterbe a következő 6 megye tartozik: az egymással határos Jász-Nagykun-Szolnok és Heves megye, valamint a külön blokkban elhelyezkedő Győr-Moson-Sopron, Veszprém és Zala megye, továbbá Tolna megye. Végül az ötödik klasztert összesen 8 megye alkotja, amelyek földrajzilag két blokkban helyezkednek el: az egyikben Bács-Kiskun, Fejér és Komárom-Esztergom megye, a másikban Nógrád, Borsod-Abaúj-Zemplén, Szabolcs-Szatmár-Bereg, Hajdú-Bihar és Békés megye.

A hierarchikus klaszterelemzés során kialakított klasztereket nem elemezzük részletesebben, mivel a módszer alkalmazásának funkciója, hogy iránymutatást adjon az optimális klaszterszámra, a k-közép klaszterezés futtatásához. A funkciót az algoritmus a 4. ábrán látható dendrogram segítségével betöltötte, melynek alapján a javasolt klaszterszám az 5. A továbbiakban a hierarchikus klaszterelemzés eredményeit összehasonlítás alapnak tekintve azt vizsgáljuk, hogy a megyék csoportosítása konzisztens-e a k-közép eljárás által javasolt csoportosítással. Ezzel pedig meggyőződhetünk a kialakult klaszterek stabilitásáról.

5. ábra

A fekvőbeteg-ellátást leíró NEAK-változók alapján képzett k-közép klaszterek Magyarországon

Results of k-means clustering based on the NHIFM-variables describing inpatient care in the counties of Hungary



Forrás: [3] alapján saját szerkesztés.

A második alkalmazott klaszterezési módszer a k-közép klaszterezés. A szilutt módszer alapján is ellenőriztük az optimális klaszterszámot, melynek eredménye a hierarchikus klaszterezéshez hasonlóan $k=5$ volt. Az egyedek szintjén használt távolságmérték továbbra is euklideszi. A magyar megyékből képzett k-közép klaszterek az 5. ábrán láthatók.

A k-közép klaszterezés során két 1, egy 2 és két 8 elemű klasztert kaptunk. A különböző klaszterek fő jellemzőit a k-közép eljárás végén kialakult klaszterközepek alapján adjuk meg (Melléklet M1. táblázat).

Az első klaszterbe egyedül Pest megye került, ahol a halálozási arány az országos átlaghoz képest a fekvőbeteg-ellátásban az aktív osztályokon kiugróan magas, az átlag alatti leterheltség ellenére. A krónikus és egyéb (újszülött- és nappali) ellátásban viszont átlag alatti a halálozási arány, annak ellenére, hogy az átlagosnál magasabb a leterheltség.

A második klasztert egyedül Baranya megye alkotja, amelyik a fekvőbeteg-ellátás terén egészségügyi szempontból jól teljesít, mivel halálozási aránya nem magasabb az országos átlagnál. Az aktív és krónikus osztályokon igen magas a leterheltség, de magas az ágykapacitás is. Az egyéb osztályokon pedig az ápolás időtartama hosszabb az átlagnál.

Somogy és Békés megye alkotja a harmadik klasztert. A fekvőbeteg-ellátásban az aktív osztályok leterheltsége az átlagnál alacsonyabb. A krónikus osztályokon – az átlag alatti leterheltség ellenére – kiugróan magas a halálozási arány, viszont ez összefügghet azzal, hogy a harmadik klaszterben magas a 65 éves és idősebb lakosság aránya. Mindezekon kívül az egyéb osztályok halálozási aránya is átlag feletti.

A negyedik klaszterbe a következő 8 megye került: Győr-Moson-Sopron, Komárom-Esztergom, Veszprém, Zala, Tolna, Jász-Nagykun-Szolnok, Heves és Nógrád megye. Az osztályok leterheltsége csak a krónikus osztályokon átlag feletti, viszont a krónikus ellátásban a halálozási arány mégis alacsonyabb az országos átlagnál. Ebben a klaszterben az egyéb osztályokon átlag alatti a leterheltség és átlagos a halálozás, viszont az aktív osztályokon a halálozási arány jóval meghaladja az országos átlagot, az átlagnál alacsonyabb leterheltség ellenére.

Az ötödik klasztert is 8 megye alkotja, a következők: Borsod-Abaúj-Zemplén, Szabolcs-Szatmár-Bereg, Hajdú-Bihar, Csongrád-Csanád, Bács-Kiskun, Fejér és Vas megye, valamint Budapest. Ebben a klaszterben a fekvőbeteg-ellátásban az aktív osztályok az átlagot meghaladó leterheltséggel dolgoznak, de átlag alatti halálozással. Az egyéb osztályok továbbá átlagnál magasabb ágykihasználtsággal működnek, de halálozási arányuk szintén az országos átlag alatt van. A változók alapján a krónikus osztályok működését pedig relatíve eredményesnek tekinthetjük, mert átlag alatti ágyszám és átlagnál alacsonyabb leterheltség mellett ebben a klaszterben átlagos a halálozási arány. Fontos kiemelni, hogy eredményeink alapján az ötödik klaszter az egyetlen nem egyelemű klaszter, ahol több osztály (aktív és egyéb) is az országos átlagnál nagyobb leterheltséggel dolgozik, és utóbbi az aktív és egyéb osztályokon

nem jár együtt magasan az országos átlag feletti ágykapacitással, mint ahogyan a Baranya megye alkotta második klaszterben az aktív és krónikus osztályoké.

A k-közép klaszterelemzés során kialakult öt klaszter legfontosabb jellemzőiről a fekvőbeteg-ellátás leterheltségét és halálózását tekintve a 6. táblázatban foglaljuk össze.

6. táblázat

A k-közép eljárással kialakított klaszterek legfontosabb jellemzői a fekvőbeteg-ellátás osztályainak leterheltségét és halálózási aránya szerint, az országos átlaghoz képest

Most significant features of the clusters formed by k-means clustering regarding the workload and mortality at different inpatient care wards, compared to the national average

Klaszter	Leterheltség			Halálózási arány		
	az aktív	a krónikus	az egyéb	az aktív	a krónikus	az egyéb
1.	alacsonyabb	magasabb	magasabb	kiugróan magas	alacsonyabb	alacsonyabb
2.	kiugróan magas	magasabb	alacsonyabb	kiugróan alacsony	kiugróan alacsony	alacsonyabb
3.	alacsonyabb	alacsonyabb	alacsonyabb	alacsonyabb	kiugróan magas	magasabb
4.	alacsonyabb	magasabb	alacsonyabb	magasabb	alacsonyabb	átlagos
5.	magasabb	alacsonyabb	magasabb	alacsonyabb	átlagos	alacsonyabb

Forrás: [3] alapján saját szerkesztés.

A hierarchikus és a k-közép klaszterelemzés után megvizsgáltuk a két módszer konzisztenciáját. Ehhez a Cramer-mutatót használtuk, amelynek értéke 0,76 lett. Ez alapján azt állapíthatjuk meg, hogy viszonylag erős a kapcsolat a két csoportosítás között, vagyis erős a hasonlóság a hierarchikus és a k-közép módszer által kialakított klaszterek között, továbbá az eljárások konzisztensek és a kialakult klaszterek stabilak.

A k-közép eljárás során kialakult 5 klaszter segítségével leírható megyei szintű különbségeket a fekvőbeteg-ellátás COVID-19-járvány előtti állapotában (amelyek legfontosabb jellemzőit az alfejezet korábbi bekezdéseiben és a 6. táblázatban foglaltunk össze) adottságnak tekintjük jelen kutatásunk további részében. Ezekkel a fekvőbeteg-ellátás szerinti adottságokkal kísérjük meg a COVID-19-halálózási arányok területi különbözőségeit magyarázó modellünk bővítését. A klaszterek kialakulása mögötti tényezők feltárása ugyanakkor további kutatások tárgyát képezheti.

A fekvőbeteg-ellátás szerinti klaszterek beépítése a regressziós modellbe

Mielőtt a járások k-közép klaszterek szerinti tagságával bővítenénk a 4. táblázat szűkített modelljét, egyszerű leíró statisztikai eszközökkel megvizsgáljuk a klasztertagság és a járások COVID-19-halálózási aránya közötti összefüggéseket (7. táblázat).

Megállapíthatjuk, hogy az átlagos és a medián COVID-19-halálózási arány az ötödik klaszterben lévő járásokban a legmagasabb, bár ebben a klaszterben a legmagasabb a halálózási arányok szórása is. A harmadik az egyetlen olyan másik klaszter,

ami megközelíti az ötödik klaszter medián és átlagos halálozási arányát. Az előző alfejezet eredményei alapján azonban a harmadik klaszter magas COVID-19-halálózása feltehetően a 65 éves és idősebb lakosság magas arányával magyarázható, ami a klaszter krónikus osztályon tapasztalt magas halálozási arányainak hátterében is állhat. További fontos észrevétel, hogy az ötödik klaszterben lévő járások száma (74) nagyságrendileg összemérhető a másik négy klaszterben lévő járások számának összegével (102).

7. táblázat

A járások száma, medián és átlagos COVID-19-halálozási aránya és annak szórása a k-közép algoritmus által javasolt klaszterek szerint

The number of districts, mean, median, standard deviation of COVID-19 mortality rates in the clusters proposed by the k-means algorithm

Klaszter	Járások száma	Medián	Átlagos	A halálozási arány szórása
		halálozási arány		
1.	18	3,243	3,367	0,841
2.	10	3,839	4,397	1,378
3.	17	4,517	4,818	1,063
4.	57	4,221	4,444	1,373
5.	74	4,535	4,996	1,704
Végösszeg	176	4,285	4,599	1,535

Forrás: [1] és [3] alapján saját szerkesztés.

Az ötödik klaszter elemszámában és COVID-19-halálozási arányban is eltérő a többi klasztertől, ezért a regressziós modellezés során az első négy klasztert összevonjuk. Ennek elsődleges oka, hogy az első négy klaszter együttes elemszáma alacsonyabb, mint az ötödik klaszteré, így együttthatójuk csak aránylag nagyobb hibával lenne becsülhető. Másodlagos ok, hogy halálozási arány szerint az ötödik klaszter némileg különbözik: a benne lévő járásokban a várható halálozási arány magasabb. Ezek után azt vizsgáljuk, hogy ez az eltérő viselkedés a korábban alkalmazott kontrollváltozók (munkanélküliség, ápolók száma, 65 éves és idősebb nők aránya) mellett is megmarad-e. Ezt technikailag egy *NEAK_Dummy5* változó felvételével oldjuk meg a 4. táblázat szűkített modelljében, aminek értéke 1, ha a járás az ötödik klaszterben található, egyébként pedig 0.

Ehhez a reprezentációhoz egy kézenfekvő értelmezést is társíthatunk. Az előző alfejezet elemzése és a Melléklet M1. táblázat alapján kijelenthetjük, hogy az országos átlaghoz képest az ötödik klaszter kórházaiban az aktív osztályok leterheltsége magas, a Baranya megyét jelentő második klasztert leszámítva a legmagasabb, ráadásul ebben a klaszterben az aktív osztályok ágykapacitása sem olyan magas, mint az említett megyében. Továbbá, az ötödik klaszterben az egyéb fekvőbeteg-osztályok leterheltsége ágykihasználtságban is országos átlag feletti, az első klasztert, azaz Pest megyét leszámítva a legmagasabb. Ez a leterheltség az osztályok 2019. évi halálozási

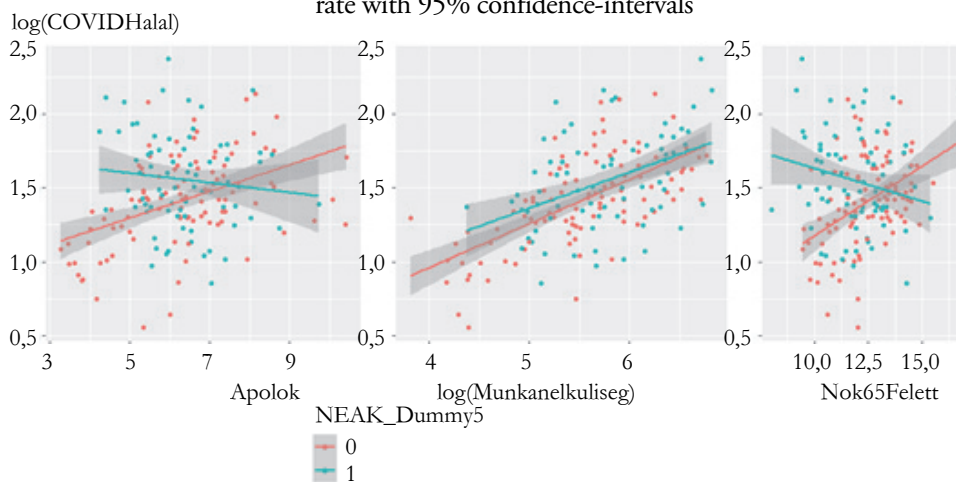
adataiban nem okozott országos átlagon felüli halálozást, ám könnyen lehet, hogy a COVID-19-járvány ezeket az eleve leterhelt kórházakat viselte meg a legnagyobb mértékben. A klaszter magas halálozási aránya ezt támasztja alá. Kérdés, hogy ez szignifikáns hatásnak bizonyul-e a szűkített regressziós modellben, a kontrollváltozók alkalmazása mellett.

Vizsgáljuk továbbá a szűkített modell 3 folytonos magyarázó változóinak lehetséges interakcióit a *NEAK_Dummy5* változóval. Ez annak ellenőrzését jelenti, hogy az ötödik fekvőbeteg-ellátás szerinti klaszterhez tartozó járásokban az ország többi járásához képest a háziorvosi szolgálathoz tartozó ápolók tízezer főre jutó számának, valamint a 65 éves és idősebb női népesség és a munkanélküliség marginális hatása a COVID-19-halálozási arányokra eltérő-e. Ehhez először vizualizációs eszközöket alkalmazunk (6. ábra).

6. ábra

Az *Apolok* x *NEAK_Dummy5*, *log(Munkanélküliség)* x *NEAK_Dummy5* és *Nok65Felett* x *NEAK_Dummy5* interakciós hatások vizsgálata a *COVIDHalal* változóra

Scatter plot of the *Nurses* x *NEAK_Dummy5*, *log(Unemployment)* x *NEAK_Dummy5* and *FemaleAbove65* x *NEAK_Dummy5* interaction effects to the COVID-19 mortality rate with 95% confidence-intervals



Megjegyzés: pontdiagram, 95%-os konfidenciaintervallumokkal.
Forrás: [1–3] alapján saját szerkesztés.

A 6. ábra szerint az *Apolok* és *Nok65Felett* változók esetén tér el jelentősen a *COVIDHalal* változóval vett kétváltozós regressziós egyenes meredeksége az ötödik klaszterben, az ország többi részéhez képest, a 95%-os konfidenciaintervallumot is figyelembe véve. Tehát, a 4. táblázat szűkített modelljét az *Apolok* x *NEAK_Dummy5* és *Nok65Felett* x *NEAK_Dummy5* interakciós hatásokkal kísérjük meg bővíteni.

Továbbá, érdekes jelenség a 6. ábrán, hogy az ötödik klaszterben a *Nok65Felett* regressziós egyenesének meredeksége negatív, e klaszteren kívül az *Apolok* változó regressziós egyenesének meredeksége viszont pozitív. Ez azt jelenti, hogy míg az ápolók tízezer főre jutó számának növekedése az ötödik klaszteren kívüli járásokban várhatóan növeli, addig a 65 éves és idősebb nők arányának emelkedése az e klaszterben található járásokban várhatóan csökkenti a COVID-19-halálozási arányt. Ezek a nem logikusnak tűnő hatások abból adódnak, hogy az ötödik klaszterben a *Nok65Felett* változó korrelál a *Munkanelküliség* logaritmusával, míg az ötödik klaszteren kívül az *Apolok* változóra igaz ugyanez: $r_{\ln Mnk, Apolok} = 0,592$ az ötödik klaszteren kívül és $r_{\ln Mnk, Nok65Felett} = -0,518$ pedig az ötödik klaszterben. Tehát, a klaszterbe sorolt járásokban az ápolók tízezer főre jutó magas száma, illetve a 65 éves és idősebb nők alacsony aránya esetén csak azért magas a COVID-19-halálozás, mert ezekben a járásokban az álláskereső tízezer főre jutó száma szintén eleve magas. Tehát a járás népességének alap egészségi állapota is rosszabb (hiszen az álláskereső tízezer főre jutó számát ennek indikátorának tekinthetjük). Amint megtisztítjuk ettől a confounding hatástól a kapcsolatokat, a meredekségek előjelei a várakozásnak megfelelően alakulnak, vagy az együttthatók erősen nem szignifikánsak lesznek, ahogy azt a 8. táblázat mutatja is.

A 8. táblázatban megvizsgált négy modell közül választani csak a három alkalmazott modellszelekciós kritérium (korrigált R-négyzet, AIC és BIC) alapján tudunk, hiszen az interakciók által okozott strukturális multikollinearitás miatt az interakciós tagok és az interakciókban részt vevő változók együttthatói csak extrém magas standard hibával becsülhetők. Vizsgált kritériumaink alapján egyértelműen a csak *Apolok* x *NEAK_Dummy5* interakciót tartalmazó modell preferált. Ráadásul, ez az a modell, ami a 4. táblázat szűkített modelljénél is jobban illeszkedőnek bizonyul az adatainkra az összes vizsgált kritérium szerint. A 8. táblázat mutatói alapján a preferált modell diagnosztikailag is megfelelőnek tekinthető. A modellre futtatott Ramsey-féle RESET teszt p-értéke 0,8991, így a modell minden szokásos szignifikanciaszinten jól specifikálhatónak is tekinthető. A modell magyarázó ereje, az R-négyzet mutató (39,18%) alapján továbbra is közepesnek számít.

A végső, csak *Apolok* x *NEAK_Dummy5* interakciót tartalmazó modellben a 10 feletti VIF értékű *NEAK_Dummy5* és *Apolok* x *NEAK_Dummy5* tagok együttthatója a parciális t-próbák alapján szignifikánsnak tekinthető minden szokásos szignifikanciaszinten. Az egyetlen, egyik szokásos szignifikanciaszinten sem szignifikáns együtttható (*Apolok*) esetében a VIF mutató alapján nem az interakció miatti strukturális multikollinearitás miatt adódik a jelenség.

8. táblázat
A NEAK_Dummy5 változóval és annak lehetséges interakciós hatásaival bővített modellek LNM-becslésű paraméterei és legfontosabb diagnosztikai mutatói

Parameters and model diagnostic measures for the extended linear models with NHIFM_Dummy5 interaction effects estimated by OLS

Y: ln(COVIDHalal)	Interakciók nélkül			Két interakcióval			Csak Apolok			Csak Nok65Felett		
	koef- ciens	p-érték	VIF	koef- ciens	p-érték	VIF	koef- ciens	p-érték	VIF	koef- ciens	p-érték	VIF
Konstans	-0,573	0,020	1,57	-0,674	0,009	2,24	-0,592	0,015	—	-0,700	0,007	—
Apolok	-0,029	0,113	1,44	-0,003	0,870	1,66	0,001	0,990	2,17	-0,031	0,090	1,57
ln(Munkanelkuliseg)	0,306	0,000	1,25	0,281	0,000	2,64	0,294	0,000	1,46	0,285	0,000	1,66
Nok65Felett	0,038	0,008	1,11	0,045	0,030	96,68	0,030	0,035	1,31	0,059	0,003	2,42
NEAK_Dummy5	0,090	0,033	1,57	0,952	0,015	31,02	0,632	0,003	28,84	0,638	0,084	85,08
Apolok x NEAK_Dummy5	—	—	—	-0,079	0,020	83,34	-0,086	0,009	29,63	—	—	—
Nok65Felett x NEAK_Dummy5	—	—	—	-0,030	0,323	2,24	—	—	—	-0,045	0,134	79,61
R-négyszet	0,3671			0,3953			0,3918			0,3755		
Korrigált R-négyszet	0,3523			0,3738			0,3739			0,3571		
AIC	33,7184			29,7089			28,7302			33,3916		
BIC	52,7413			55,0727			50,9236			55,5850		
White négyzetekkel és interakciókkal (p-érték)	0,7480			0,9580			0,8620			0,8020		
Jarque-Bera (p-érték)	0,6546			0,7424			0,6984			0,6309		

Megjegyzés: A táblázatban alkalmazott rövidítések feloldása a következő. VIF = variancia inflációs faktor; AIC = Akaike információs kritérium; BIC = Bayes–Szwartz információs kritérium. A modellek kiértékeléséhez alkalmazott mutatók és az elvégzett hipotézisvizsgálatok p-értékei mögött álló statisztikai próbák részletes leírását lásd Wooldridge (2010).

Forrás: [1–3] alapján saját szerkesztés.


A 4. táblázat szűkített modelljéhez képest a NEAK klasztertagsággal és ennek az ápolószámmal vett interakciójával bővített modell két új következtetéssel szolgál a járások COVID-19-halálozási arányainak alakulásáról. Az egyik, hogy a fekvőbeteg-ellátás alapján az ötödik klaszterbe tartozó járásokban (tehát ahol jóval az országos átlag feletti a kórházak aktív és egyéb osztályainak leterheltsége együttesen) a halálozási arány átlagos szintje szignifikánsan magasabb azonos munkanélküliség, 65 éves és idősebb nőarány és tízezer főre jutó ápolószám mellett is. Ezt a hatást a *NEAK_Dummy5* minden szokásos szignifikanciaszinten szignifikánsan pozitív együttthatója támasztja alá. Tehát, a modellezés alapján is kijelenthető, hogy a COVID-19-járvány azokat a járásokat érintette a súlyosabban, ahol a kórházak aktív és egyéb osztályai együttesen már a járvány előtt, 2019-ben is eleve leterheltebbek voltak az országos átlagnál. Fontos megjegyezni, hogy a 6. táblázat alapján e járások leterhelt aktív és egyéb kórházi osztályain országos átlag alatti volt a halálozási arány 2019-ben. Ennek ellenére okozott a COVID-19-járvány a többi járáshoz képest magasabb halálozási arányokat ezekben a járásokban. Ebből arra következtethetünk, hogy az érintett kórházak erőforrásai kimerültek a járvány első két hulláma során. Gombos et al. (2021) is kiemeli a kórházi kapacitásban a megyék közötti jelentős különbségeket. Modellünk alapján ezen különbségeknek már önmagukban, a modellben szereplő egyéb változók mellett is önálló COVID-19-halálozási arányt növelő hatása volt.

Ezen túl, a *NEAK_Dummy5* változó interakciója az ápolószámmal a 7. ábrán bemutatott hatást fejtette ki.

7. ábra

A végső modell alapján becsült COVIDHalal értékek az Apolok változó függvényében, a NEAK_Dummy5 változó szerint megbontva

Estimated COVID-19 mortality rates by the final model as a function of the Nurses variable separated by the NHIFM_Dummy5 feature with 95% confidence-intervals



Megjegyzés: 95%-os konfidenciaintervallumokkal.

Forrás: [1–3] alapján saját szerkesztés.

A 7. ábra alapján magyarázatot adhatunk az interakciós hatás nélküli *Apolok* változó 12%-os p-értékére a 4. táblázat szűkített modelljében. Ugyanis, az átlag feletti leterheltségű aktív és egyéb osztályokkal rendelkező kórházak járásaiban a háziorvosi szolgálathoz tartozó ápolók tízezer főre jutó számának minden szokásos szignifikanciaszinten szignifikáns a halálozási arányt csökkentő hatása (változatlan 65 éves idősebb női népesség és munkanélküliség mellett). Ellenben, a többi járás esetében az ápolók tízezer főre jutó száma lényegében nincs hatással a COVID-19-halálozási arányok alakulására. E két hatás együttes megjelenése a 4. táblázat szűkített modelljében okozta az *Apolok* változó magasabb p-értékét. Az 5. klaszterben megfigyelt, ám a többi járásban nem megfigyelt hatás logikusnak tűnik, hiszen azon járásokban értékelődik fel a háziorvosi szolgálathoz tartozó ápolók száma, ahol a fekvőbeteg-ellátás leterheltsége már a járvány előtt is magas az országos átlag feletti volt, egyezre több (aktív és egyéb) osztályon is. A COVID-19-fertőzöttek okozta többletterhelés miatt kimerült kórházi erőforrások következtében feltehetően több fertőzött ellátása jutott a háziorvosi szolgálatra, ahol elsősorban az ápolók végzik a közvetlen ellátást. Az azonosított jelenség arra hívja fel a figyelmet, hogy a háziorvosi szolgálathoz tartozó ápolók tízezer főre jutó számában mutatkozó területi különbségek kiegyenlítését az országos átlag feletti leterheltségű fekvőbeteg-ellátással rendelkező járásokban szükséges megkezelni.

Megbeszélés és összegzés

Jelen dolgozatban a magyar járások COVID-19-halálozási arányaira építettünk egyszerű statisztikai modellt a [2] és a [3] adatbázisok ágyszám- és betegforgalmi kimutatásából származó magyarázó változók segítségével. A modellépítés során két változó, a háziorvosok tízezer főre jutó száma és a 65 éves és idősebb férfinepesség aránya elhagyható volt. Utóbbi két változó ugyanis nem magyarázza érdemben a járások halálozási arányainak alakulását.

A végső, diagnosztikailag megfelelőnek tekinthető modellünk alapján a következő, minden szokásos szignifikanciaszinten szignifikáns marginális hatások azonosíthatók:

- Változatlan 65 éves és idősebb női népesség, az ápolók tízezer főre jutó száma, valamint leterheltség szerinti klaszterbe tartozás mellett, ha egy járásban 1%-kal nő a tízezer főre jutó álláskereső száma, akkor a COVID-19-halálozási arány várhatóan 0,29%-kal emelkedik. A pozitív irányú hatás feltehetően azzal magyarázható, hogy a munkanélküliség a járás népességének egészségi állapotára vonatkozó indikátorként alkalmazható (Bíró–Elek 2020, Ruhm 2016). Az a tény, hogy ennek az indikátorváltozónak a járó- és fekvőbeteg-ellátás állapotára és az időskorú népesség arányára vonatkozó változók mellett is szignifikáns COVID-19-halálozást növelő hatása van, megerősíti Páger et al. (2021) azon kezdeti következtetését, amely szerint a magasabb

COVID-19-halálozási arányszámokat a társadalmi-gazdasági értelemben hátrányosabb területeken figyelhetjük meg.

- Jellemzően az átlagos COVID-19-halálozási arány szintje a leterhelt aktív és egyéb osztályú kórházakkal rendelkező járásokban magasabb, azonos munkanélküliség, 65 éves és idősebb női népesség és az ápolók tízezer főre jutó száma mellett is. Tehát, a modellünk alapján a COVID-19-járvány ezeket az eleve leterhelt kórházakkal rendelkező járásokat viselte meg a legnagyobb mértékben. Hiába volt a járások leterhelt aktív és egyéb kórházi osztályain országos átlag alatti a halálozási arány 2019-ben, a COVID-19-járvány a többi járáshoz képest magasabb halálozási arányokat okozott bennük, amiből arra következtethetünk, hogy az érintett kórházak erőforrásai kimerültek a járvány első két hulláma során.
- Az átlag feletti leterheltségű aktív és egyéb osztályokkal rendelkező kórházak járásában a háziorvosi szolgálathoz tartozó ápolók tízezer főre jutó számának minden szokásos szignifikanciaszinten szignifikáns COVID-19-halálozási arányt csökkentő hatása van. Változatlan 65 éves és idősebb női népesség, valamint munkanélküliség mellett a járásban eggyel több ápoló várhatóan 8,2%-kal csökkenti a halálozási arányt. Ellenben, a többi járás esetében az ápolók tízezer főre jutó számának lényegében nincs marginális hatása. Az eredmény alapján azon járásokban értékelődik fel a háziorvosi szolgálathoz tartozó ápolók száma, ahol a fekvőbeteg-ellátás leterheltsége már a járvány előtt több osztályon is országos átlag feletti volt. Emiatt feltehető, hogy a háziorvosi szolgálatra több fertőzött ellátása jut, ahol elsősorban az ápolók végzik a közvetlen ellátást.
- A 65 éves és idősebb női népesség marginális hatása a COVID-19-halálozási arányra 1%-os szignifikanciaszinten már nem szignifikáns, de 5%-on még igen. Ez alapján változatlan az álláskeresők, az ápolók és a háziorvosok tízezer főre jutó száma, valamint leterheltségi klaszterbe tartozás mellett, ha egy járásban 1 százalékponttal nő a 65 éves és idősebb női népesség aránya, akkor várhatóan 3%-kal nő a COVID-19-halálozási arány is. Ez alátámasztja azt a nemzetközi tapasztalatot, hogy a COVID-19 leggyakrabban a 65 éves és idősebb népesség körében halálos kimenetelű (Bonanad et al. 2020, Kang–Jung 2020). Említésre méltó azonban, hogy a magyar járásokban ez a hatás a nők körében figyelhető meg, a férfiak esetében nem. Ennek hátterében az állhat, hogy a 2017. évi magyar halandósági tábla alapján a 45–65 éves korcsoportba tartozó és rosszabb egészségi állapotban lévő férfiak jelentős hányada hunyt el. Így azok, akik megélik a 65 éves életkort már a COVID-19-cel szemben is ellenállóbbak. A jelenséget az okozhatja, hogy ebben a korcsoportban valószínűleg kevesebb a társbetegség, amelyek pedig elsődleges kockázati tényezők a COVID-19 miatti halálozásban (Banerjee et al. 2020, Mohamed et al. 2020).

Jelen kutatásnak több korlátja is azonosítható, melyek feloldása további kutatások tárgyát képezheti.

Az egyik irány a vizsgált változók körének bővítése. A [2] adatbázis segítségével még számos COVID-19-halálozási arányt magyarázó változó rendelkezhet a járásokhoz. A járás betegellátásának 2019. évi állapota még olyan változók segítségével is jellemezhető lenne, mint a háziorvosi szolgálat által ellátott esetek tízezer főre jutó száma, vagy ennek ápolókra és háziorvosokra vetített száma, továbbá a tízezer főre vetített gyógyszerterek és szakrendelések száma is vizsgálható. A járás lakosságának egészségi állapotát nem csupán a tízezer főre jutó álláskereső számával, mint indikátórváltozóval lehetne leírni. A gyógyszerforgalom alapján végzett becsléssel közvetlenül kimutatható akár a különböző alapbetegségekben (keringési rendszer, légzőrendszer megbetegedései, mentális zavarok stb.) érintettek gyakorisága is a járásokban. Elsősorban a daganatos, a keringési és az emésztőrendszeri megbetegedések kaptak nagyobb visszhangot (Banerjee et al. 2020, Mohamed et al. 2020), így ezek területi kutatása további információkat adhat a COVID-19-halálozási arány területi különbségeinek okairól. Ezen kívül, a járási lakosság iskolázottságának és jövedelmi helyzetének vizsgálata is bevonható az elemzésbe, utóbbi például a járásban élők személyijövedelemadó-alapjának tízezer főre vetített összegének vizsgálatával. Természetesen, a 175-ös megfigyelésszám mellett egyszerre 35 változónál többet alkalmazni nem tanácsos a modellben. Amennyiben az NNK frissebb vagy időbeli bontásban jobban egymáshoz rendelhető települési vagy járási szintű fertőzött- és halálozási számokat tesz közzé, akkor az új modellek eredményváltozóiban már érdemes lenne ezeket alkalmazni.

A másik bővítési irány a módszertan fejlesztése lehet, strukturális egyenletrendszer-modell (SEM) alkalmazásával. A SEM lehetővé teszi moderáló és mediáló hatások vizsgálatát is. Például az esetleges endogén hatások figyelembevételével az is megállapítható lenne, hogy a járásban az álláskereső tízezer főre jutó száma valóban a lakosság általános egészségi állapotának (különböző alapbetegségek előfordulási gyakorisága) hatását mediálja-e a halálozási arányokra. Továbbá, vizsgálható az is, hogy van-e ennek a mutatónak ezen túl is hatása a halálozásokra, és az milyen irányú.

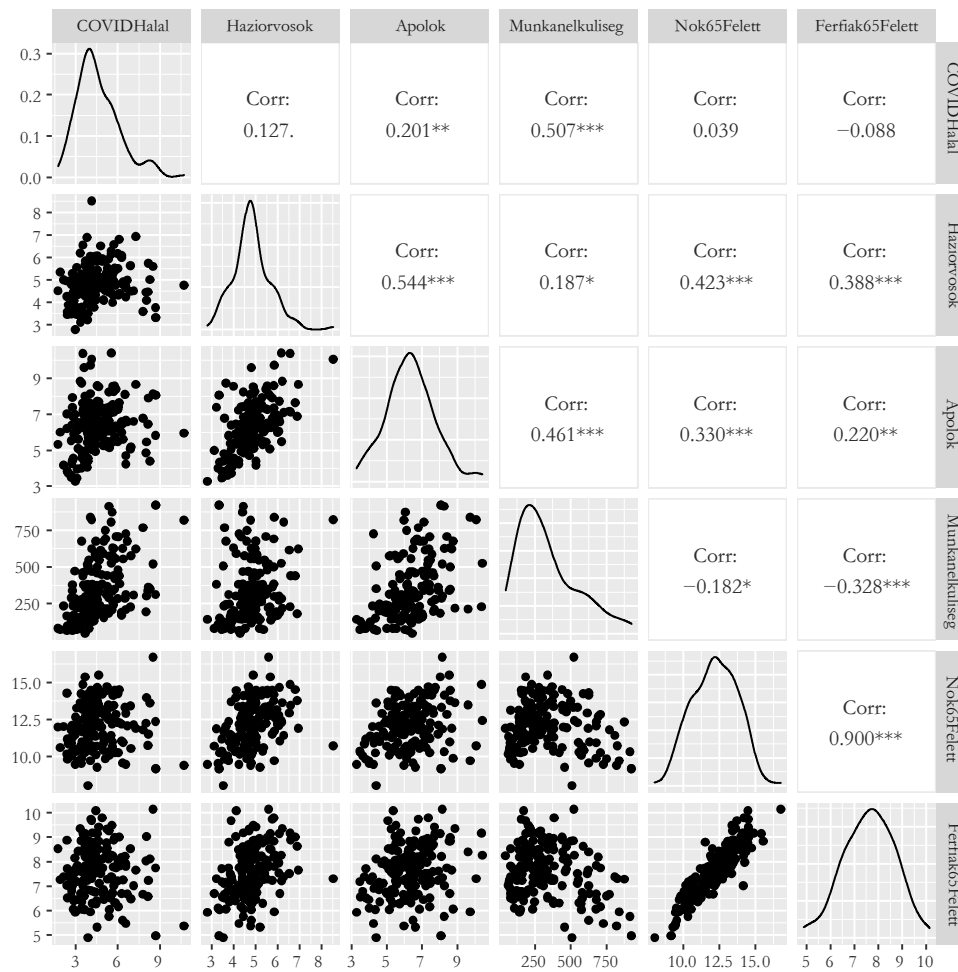
Jelen tanulmány célja viszont mindössze az volt, hogy a magyar járások COVID-19-halálozási arányaira ható alapvető tényezők (lakosság egészségi állapota, járó- és fekvőbeteg-ellátás állapota) hatását számszerűsítse, amit a végső lineáris modellel sikerült is elérni. Ezt a végső lineáris modellel sikerült is elérni, bár a feltárt statisztikai összefüggések mellett bizonyos más tényezők is hathatnak, melyre ez az elemzés nem térhetett ki.

Melléklet

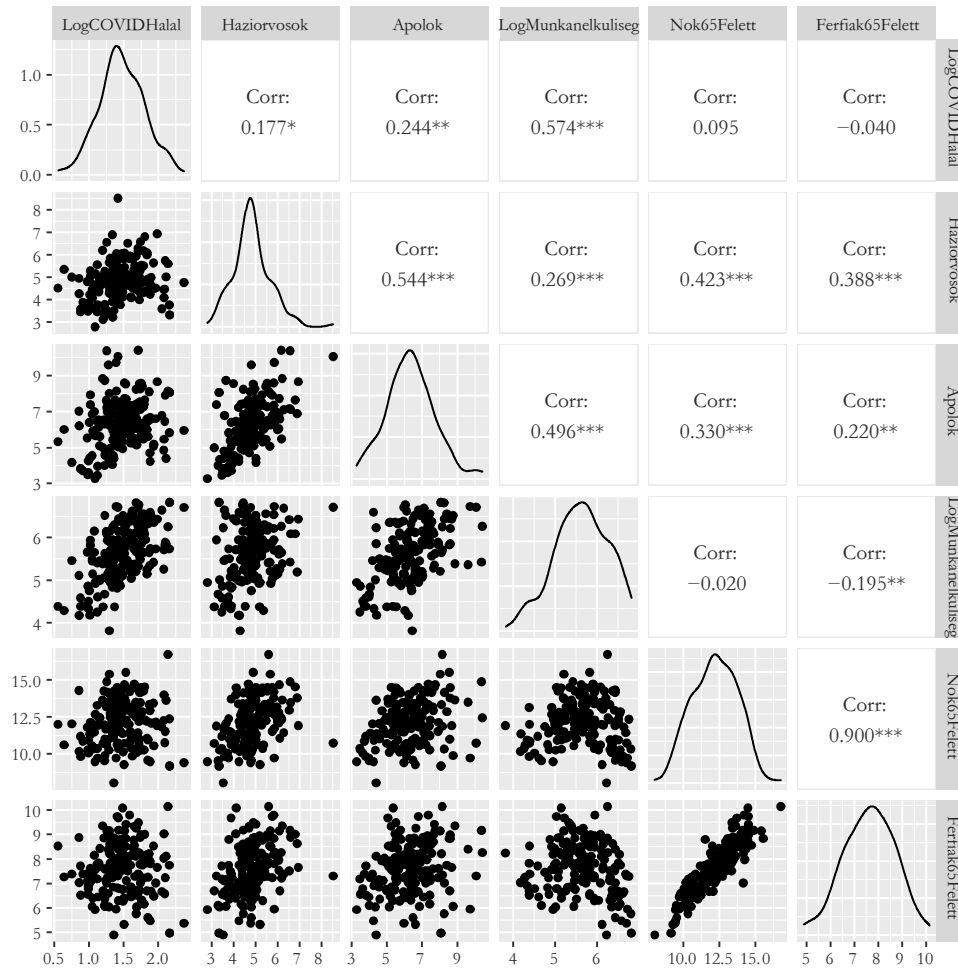
M1. ábra

Az 1. és a 2. táblázatok változóinak hisztogramja és korrelációja
Histogram and correlation of the variables in Tables 1 and 2

A jobbra elnyúló változók logaritmálása nélkül



A jobbra elnyúló változók logaritmálása után




Megjegyzés: Az ábrák angol nyelvű programcsomaggal készültek. Az ábrán szereplő *Corr* a *korreláció* angol rövidítése.

M2. ábra

Optimális klaszterszám Optimal number of clusters

Klasztereken belüli teljes négyzetösszeg



Megjegyzés: A belső eltérés-négyzetösszegek hierarchikus klaszterelemzés esetén, különböző klaszterszámok függvényében.

M1. táblázat

A k-közép klaszterelemzés klaszterei
Clusters of k-means cluster analysis

Klaszter	egynaposellátásaktív	ápolásiidőkrónikus	ápolásiidőgyéb
1.	-1,61	1,45	1,34
2.	1,76	-0,25	3,37
3.	-0,53	1,47	0,31
4.	-0,20	-0,11	-0,32
5.	0,32	-0,41	-0,35
Klaszter	ténylegeselbocsátottkrónikus	halálozáskrónikus	halálozásgyéb
1.	1,17	-0,80	-0,41
2.	1,47	-1,46	-0,47
3.	-1,97	2,10	0,98
4.	0,42	-0,26	0,05
5.	-0,26	0,01	-0,18
Klaszter	ágykihasználtsággyéb	teljesítettaránygyéb	ténylegeselbocsátottegyéb
1.	1,46	1,96	0,61
2.	-0,15	0,92	-1,17
3.	-0,44	-1,03	-2,35
4.	-0,94	0,02	0,37
5.	0,89	-0,13	0,29
Klaszter	áthelyezettkrónikus	áthelyezettgyéb	halálozásaktív
1.	-1,51	-0,61	1,65
2.	-1,06	1,19	-1,60
3.	1,15	2,35	-0,22
4.	-0,60	-0,38	0,59
5.	0,64	-0,28	-0,54
Klaszter	PC1=ágyakaktív	PC2=ágyakkrónikus	PC3=betegforgalomaktív
1.	-3,03	-1,37	0,73
2.	1,37	0,46	-0,31
3.	-0,25	0,35	-0,06
4.	0,04	0,40	0,22
5.	0,23	-0,38	-0,26
Klaszter	PC4=leterheltségaktív	PC5=ágyakegyéb	PC6=leterheltségkrónikus
1.	-0,30	-0,73	0,18
2.	1,41	-0,97	0,89
3.	-0,48	0,42	-0,38
4.	-0,52	-0,19	0,49
5.	0,50	0,29	-0,53

Megjegyzés: Az elemzésbe bevont változók a teljes adatbázis tekintetében 0 átlagúak és 1 szórásúak.

IRODALOM

- BÁLINT, CS. (2021): Pillanatkép a háziorvosi és házi gyermekorvosi alapellátás járási szintű területi egyenlőtlenségeiről a koronavírus-járvány előtti időszakból *Multidiszciplináris kibívások, sokszínű válaszok – Gazdálkodás- és Szervezéstudományi folyóirat* 1: 78–107. <https://doi.org/10.33565/MKSV.2021.01.04>
- BANERJEE, A.–PASEA, L.–HARRIS, S.–GONZALEZ-IZQUIERDO, A.–TORRALBO, A.–SHALLCROSS, L.–NOURSADEGHI, M.–PILLAY, D.–SEBIRE, N.–HOLMES, C.–PAGEL, C.–KEONGWONG, W. –LANGENBERG, C.–WILLIAMS, B.–DENAXAS, S.–HEMINGWAY, H. (2020): Estimating excess 1-year mortality associated with the COVID-19 pandemic according to underlying conditions and age: a population-based cohort study *The Lancet* 395 (10238): 1715–1725. [https://doi.org/10.1016/S0140-6736\(20\)30854-0](https://doi.org/10.1016/S0140-6736(20)30854-0)
- BÍRÓ, A.–ELEK, P. (2020): Job loss, disability insurance and health expenditure *Labour Economics* 65: 101856. <https://doi.org/10.1016/j.labeco.2020.101856>
- BOCCIA, S.–RICCIARDI, W.–IOANNIDIS, J. P. A. (2020): What other countries can learn from Italy during the COVID-19 pandemic *JAMA* 180 (7): 927–928. <http://dx.doi.org/10.1001/jamainternmed.2020.1447>
- BOGOS, K.–KISS, Z.–KERPEL FRONIUS, A.–TEMESI, G.–JENŐ, E.–MADURKA, I.–CSELKÓ, ZS.–CSÁNYI, P.–ABONYI-TÓTH, ZS.–ROKSZIN, GY.–BARCZA, ZS.–MOLDVAY, J. (2021): Different trends in excess mortality in a Central European country compared to main European regions in the year of the COVID-19 pandemic (2020): a Hungarian analysis *Pathology and Oncology Research* 27: 84. <https://doi.org/10.3389/pore.2021.1609774>
- BONANAD, C.–GARCIA-BLAS, S.–TARAZONA-SANTABALBINA, F.–SANCHIS, J.–BERTOMEU-GONZÁLEZ, V.–FACILA, L.–ARIZA, A.–NÚÑEZ, J.–CORDERO, A. (2020): The effect of age on mortality in patients with COVID-19: a meta-analysis with 611,583 subjects *Journal of the American Medical Directors Association* 21 (7): 915–918. <https://doi.org/10.1016/j.jamda.2020.05.045>
- BOROS, L.–KOVALCSIK, T. (2021): A COVID-19-járvány hatása a budapesti Airbnb-piacra *Területi Statisztika* 61 (3): 380–402. <https://doi.org/10.15196/TS610306>
- BRO, R.–SMILDE, A. K. (2014): Principal component analysis *Analytical methods* 6 (9): 2812–2831. <https://doi.org/10.1039/C3AY41907J>
- COHEN, J. F.–KOREVAAR, D. A.–MATCZAK, S.–CHALUMEAU, M.–ALLALI, S.–TOUBIANA, J. (2021): COVID-19-related fatalities and intensive-care-unit admissions by age groups in Europe: A meta-analysis *Frontiers in medicine* 7: 1097. <https://doi.org/10.3389/fmed.2020.560685>
- CZIRFUSZ, M. (2021): A COVID-19-válság és a térbeli munkamegosztás változásai Magyarországon *Területi Statisztika* 61 (3): 320–336. <https://doi.org/10.15196/TS610303>
- DÁNIEL, Z. A.–MOLNÁRNÉ BARNA, K.–MOLNÁR, T. (2021): Koronavírus-járvány a V4-országokban – társadalmi, gazdasági hatások, regionális összefüggések, kormányzati beavatkozások *Területi Statisztika* 61 (5): 555–576. <https://doi.org/10.15196/TS610501>

- FEKETE, K.–DOMBI, G.–OLÁH, M. (2021): Önkormányzati válságkezelés a Balaton Kiemelt Üdülőkörzetben, a COVID-19-járvány első hullámában *Területi Statisztika* 61 (3): 337–355. <https://doi.org/10.15196/TS610304>
- FERENCI, T. (2021): Different approaches to quantify years of life lost from COVID-19 *European Journal of Epidemiology* 36 (6): 1–9. <https://doi.org/10.1101/2021.05.13.21257193>
- GOMBOS, K.–HERCZEG, R.–ERŐSS, B.–KOVÁCS, S. ZS.–UZZOLI, A.–NAGY, T.–KISS, SZ.–SZAKÁCS, ZS.–IMREI, M.–SZENTESI, A.–NAGY, A.–FÁBIÁN, A.–HEGYI, P.–GYENESEI, A. (2021): Translating scientific knowledge to government decision makers has crucial importance in the management of the COVID-19 pandemic *Population Health Management* 24 (1): 35–45. <https://doi.org/10.1089/pop.2020.0159>
- HUNYADI, L.–VITA, L. (2006): *Statisztika közzegadatoknak* Központi Statisztikai Hivatal, Budapest.
- KANG, S. J.–JUNG, S. I. (2020): Age-related morbidity and mortality among patients with COVID-19 *Infection & chemotherapy* 52 (2): 154. <https://doi.org/10.3947/ic.2020.52.2.154>
- KINCSES, Á.–TÓTH, G. (2020): How coronavirus spread in Europe over time: national probabilities based on migration networks *Regional Statistics* 10 (2): 228–231. <https://doi.org/10.15196/RS100210>
- KOVALCSIK, T.–BOROS, L.–PÁL, V. (2021): A COVID-19-járvány első két hullámának területisége Közép-Európában *Területi Statisztika* 61 (3): 263–290. <https://doi.org/10.15196/TS610301>
- KÖKÉNY, L.–KISS, K. (2021): There is a time and a place for everything (and for everyone): Examining main socio-demographic and territorial differences in use of leisure time *Regional Statistics* 11 (2): 136–164. <https://doi.org/10.15196/RS110206>
- KUHN, A.–LALIVE, R.–ZWEIMÜLLER, J. (2009): The public health costs of job loss *Journal of Health Economics* 28 (6): 1099–1115. <https://doi.org/10.1016/j.jhealeco.2009.09.004>
- LAWLEY, D. N.–MAXWELL, A. E. (1971): *Factor analysis as a statistical method* 2nd Edition, Butterworths, London.
- MITROFANOVA, I. V.–IVANOVA, T. B.–KLEITMAN, E. V.–MKRTCHAN, E. R. (2021): The ‘Smart city’ concept and its implementors: On the way to the information control in Volgograd Russia *Regional Statistics* 11 (1): 135–146. <https://doi.org/10.15196/RS110108>
- MOHAMED, M. O.–GALE, C. P.–KONTOPANTELI, E.–DORAN, T.–DE BELDER, M.–ASARIA, M.–LUSCHER, T.–WU, J.–RASHID, M.–STEPHENSON, C.–DENWOOD, T.–ROEBUCK, C.–DEANFIELD, J.–MAMAS, M. A. (2020): Sex differences in mortality rates and underlying conditions for COVID-19 deaths in England and Wales *Mayo Clinic Proceedings* 95 (10): 2110–2124. <https://doi.org/10.1016/j.mayocp.2020.07.009>
- MURTAGH, F.–LEGENDRE, P. (2014): Ward's hierarchical agglomerative clustering method: Which algorithms implement Ward's criterion? *Journal of Classification* 31: 274–295. <https://doi.org/10.1007/s00357-014-9161-z>

- NYIKOS, GY.–SOHA, B.–BÉRES, A. (2021): Entrepreneurial resilience and firm performance during the COVID-19 crisis – Evidence from Hungary *Regional Statistics* 11 (3): 29–59. <https://doi.org/10.15196/RS110307>
- PADULA, W. V.–DAVIDSON, P. M. (2020): Countries with high registered nurse (RN) concentrations observe reduced mortality rates of coronavirus disease 2019 (COVID-19) *Social Science Research Network Electronic Journal*: 1556–1572. <http://dx.doi.org/10.2139/ssrn.3566190>
- PÁL, V.–LADOS, G.–ILCSIKNÉ MAKRA, ZS.–BOROS, L.–UZZOLI, A.–FABULA, SZ. (2021): Concentration and inequality in the geographic distribution of physicians in the European Union, 2006–2018 *Regional Statistics* 11 (3): 3–28. <https://doi.org/10.15196/RS110308>
- PARCHA, V.–MALLA, G.–SURI, S. S.–KALRA, R.–HEINDL, B.–BERRA, L.–FOUDAD, M. N.–ARORA, G.–ARORA, P. (2020): Geographic variation in racial disparities in health and coronavirus Disease-2019 (COVID-19) mortality *Mayo Clinic Proceedings: Innovations, Quality & Outcomes* 4 (6): 703–716. <https://doi.org/10.1016/j.mayocpiqo.2020.09.005>
- REMEZYIK, B.–BARCZA, A.–CSAPÓ, J.–SZABÓ, B.–FODOR, GY.–DÁVID, L. D. (2021): Over-tourism in Budapest: Analysis of spatial process and suggested solutions *Regional Statistics* 11 (3): 179–197. <https://doi.org/10.15196/RS110303>
- ROUSSEEUW, P. J. (1987): Silhouettes: A graphical aid to the interpretation and validation of cluster analysis *Journal of Computational and Applied Mathematics* 20: 53–65. [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- RUHM, C. J. (2016): Health effects of economic crises *Health Economics* 25: 6–24. <https://doi.org/10.1002/hec.3373>
- SZÜLE, B. (2019): Klaszterszám-meghatározási módszerek összehasonlítása *Statisztikai Szemle* 97 (5): 421–438. <https://doi.org/10.20311/stat2019.5.hu0421>
- UZZOLI, A.–KOVÁCS, S. ZS. (2020): A koronavírus-járvány jelenlegi és várható egészségkárosításainak területi különbségei Magyarországon *Tér és Társadalom* 34 (2): 155–170. <https://doi.org/10.17649/TET.34.2.3265>
- UZZOLI, A.–KOVÁCS, S. ZS.–PÁGER, B.–SZABÓ, T. (2021): A hazai COVID-19-járványhullámok területi különbségei *Területi Statisztika* 61 (3): 291–319. <https://doi.org/10.15196/TS610302>
- XIE, L.–YANG, H.–ZHENG, X.–WU, Y.–LIN, X.–SHEN, Z. (2021): Medical resources and coronavirus disease (COVID-19) mortality rate: Evidence and implications from Hubei province in China *Plos One* 16 (1): e0244867. <https://doi.org/10.1371/journal.pone.0244867>
- WOOLDRIDGE, J. M. (2016): *Introductory econometrics: A modern approach* Nelson Education, Toronto.

INTERNETES FORRÁSOK

- KOVÁCS, E. (2014): *Többváltozós adatelemzés* Typotex, Budapest. http://etananyag.ttk.elte.hu/FiLeS/downloads/14_KOVACS_E_Tobbvalt_adatelemzes.pdf (letöltve: 2021. június 30.)

- NNK – NEMZETI NÉPEGÉSZSÉGÜGYI KÖZPONT (2019): *Körzeti-közösségi szakápolás szaktevékenység definíciója, szakmai leírása*
<https://www.nnk.gov.hu/index.php/egeszsegugyi-igazgatasi-foosztaly/szakmai-minimumfeltetek/268-szakapolas-korzeti-kozossegi-szakapolas>
(letöltve: 2021. augusztus 5.)
- PÁGER, B.–SZABÓ, T.–KOVÁCS, S. ZS.–UZZOLI, A. (2021): *Lakóhelytől is függhet a koronavírus-fertőzés túlélési esélye – melyek a leginkább veszélyeztetett területek a járvány idején?*
<https://www.portfolio.hu/krtk/20210617/lakohelytol-is-fugghet-a-koronavirus-fertozes-tulelesi-eselye-melyek-a-leginkabb-veszelyeztetett-teruletek-a-jarvany-idejen-488302> (letöltve: 2021. augusztus 4.)

ADATBÁZISOK/HONLAPOK

- [1] <https://bit.ly/COVID-adatok> (letöltve: 2021. június 23.)
- [2] <http://statinfo.ksh.hu/Statinfo/themeSelector.jsp?lang=hu> (letöltve: 2021. június 23.)
- [3] http://www.neak.gov.hu/data/cms1026624/Korhazi_agyszamkimutatas_2019.pdf
(letöltve: 2021. június 24.)
- [4] <https://www.mortality.org/cgi-bin/hmd/country.php?cntr=HUN&level=1>
(letöltve: 2021. június 30.)
- [5] <https://koronavirus.gov.hu/elhunytak> (letöltve: 2021. június 25.)