

IVÁNYI TAMÁS<sup>1</sup> – KOLOZSVÁRI KRISZTINA<sup>2</sup>

# A mesterséges intelligencia alkalmazhatósága az előrejelzések területén

Módszertani vizsgálat és esettanulmány MI-alapú,  
nagy nyelvi modellekre épülő scenáriók készítésére  
Magyarország népességének várható alakulásáról

## Absztrakt

Magyarország népessége az 1980-as évektől kezdődően folyamatos csökkenést és előregedést mutat, amely jelentős társadalmi-gazdasági következményekkel jár. A demográfiai előrejelzések készítése ugyanakkor bizonytalansággal terhelt, mivel az azok alapjául szolgáló paraméterek – születések, halálozások és migráció – jövőbeli alakulása nehezen prognosztizálható. A bizonytalanságok kezelésére a demográfusok különböző forгатókönyveket dolgoznak ki, és ezek alapján végeznek szimulációs számításokat. Ez a helyzet indokoltá teszi annak vizsgálatát, hogy a mesterségesintelligencia- (MI-) eszközök – különösen a nagy nyelvi modellekre épülő asszisztensek (LLM-ek) – hogyan viselkednek, ha azokat hasonló előrejelzési feladat elé állítjuk. Az elmúlt évtizedben ugyanis robbanásszerű fejlődésen mentek keresztül az MI-alapú eszközök, és az LLM-ek már komplex feladatok ellátására is alkalmassá váltak. Az MI-asszisztenseknek a kvantitatív kutatómunkában való alkalmazhatóságáról a nemzetközi szakirodalomban találunk néhány gyakorlat-orientált példát, ugyanakkor tudományos kvantitatív kutatásban és különösen a demográfiai előrejelzések területén eddig kevés empirikus tapasztalat áll rendelkezésre. Tanulmányunkban egy kísérlet eredményeit mutatjuk be, amelyben két nagy nyelvi modell – a ChatGPT 5 és a Gemini 2.5 – demográfiai előrejelzésekben való alkalmazhatóságát vizsgáltuk. A modelleket arra kértük, hogy készítsenek Magyarország népességének várható alakulására egy rövid, valamint egy hosszú távú előrejelzést. A vizsgálat során különböző részletettségű és strukturáltságú promptokat, ún. *prompt-mátrixot* alkalmaztunk annak feltárására, miként reagál-

<sup>1</sup> Egyetemi adjunktus, BME Gazdaság- és Társadalomtudományi Kar.

<sup>2</sup> Kutatási tanácsadó, Századvég Társadalmi Folyamatok és Média Kutatóintézet.

nak az egyes modellek az eltérő inputokra. Az eredmények azt mutatják, hogy rövid időhorizonton a modellek előrejelzései viszonylag megbízhatók, hosszú távon azonban a bizonytalanság jelentősen megnőtt. A migrációs paraméter mindkét modell esetében kritikus tényezőnek bizonyult, bár a Gemininél mérsékelt hatást mutatott. Azok a prompt-szintek „tűntek jobbnak” rövid távon, amelyeknél a modell szabadon választhatta meg paramétereit és számítási módszerét, valójában azonban ezek bizonyultak gyengébbnek, mivel ezekben az esetekben a modell inkább a trendek mechanikus követésére szorítkozott, a valós számítási logikát azonban nem sajátította el. Összességében az MI-asszisztensek képesek komplex előrejelzési feladatok látszólagos ellátására, de jelenlegi formájukban elsősorban kiegészítő eszközként alkalmazhatók. Esettanulmányunk azt mutatja, hogy a demográfiai előrejelzések hosszú távú bizonytalanságai nem oldhatók fel, ugyanakkor úgy gondoljuk, hogy a nyelvi modellek hozzájárulhatnak a szenárióelemzés gazdagításához és a prediktív analitika módszertani fejlődéséhez.

*Kulcsszavak:* mesterséges intelligencia, nagy nyelvi modellek, MI-asszisztensek, demográfia, előrejelzés, szenárióelemzés, esettanulmány, prediktív analitika

## Bevezetés

A jövőorientáltság egy alapvető emberi beállítódás, amely a múlt- és jelenközpontúságot ellensúlyozza, és a jövő felé irányuló gondolkodást helyezi előtérbe. Ez a szemlélet jelenik meg akkor, amikor az egyének, közösségek, intézmények és esetünkben a kutatók a múltbeli trendek és a jelenlegi adatok modellezése révén igyekeznek előre jelezni a várható folyamatokat, amelyek a hosszú távú stratégiai döntéshozatal és tervezés nélkülözhetetlen alapját képezik.

Az előrejelzések pontossága és megbízhatósága közvetlenül befolyásolja nemcsak az egyének és vállalkozások, hanem az intézmények és a kormány cselekvési terveinek hatékonyságát is. Nem véletlen, hogy a nemzetközi szakpolitikai dokumentumok is hangsúlyozzák az előrejelzések pontosságának jelentőségét: az Európai Bizottság demográfiai kihívásokra kidolgozott eszköztára<sup>3</sup> (*A toolbox for action*) például kiemeli, hogy a demográfiai és társadalmi változásokra adott válaszok sikeressége nagymértékben függ attól, hogy mennyire pontosan tudjuk megbecsülni a munkaerőpiac, az egészségügy és a nyugdíjrendszerek jövőbeli terhelését. Éppen ezért a hosszú távú előrejelzések bizonytalansága komoly kihívást jelent: az előre jelezett trendek legkisebb eltérése is teljesen más politikai válaszokat és cselekvéseket tehet szükségessé. A demográfiai előreszámításoknak ebben kiemelt szerepük van, hiszen a népességszám, a korösszetétel és a társadalmi szerkezet alakulása alapve-

<sup>3</sup> Európai Bizottság 2023.

tően meghatározza a gazdasági és társadalmi rendszerek fenntarthatóságát. Magyarországon az elmúlt két évtized előrejelzései következetesen jelezték a népesség tartós csökkenését és az elöregedés felgyorsulását. Bár a modellezési eljárások sokat fejlődtek – a determinisztikus számításoktól a regionális bontású és valószínűségi megközelítésekig –, bizonyos tényezők, mindenekelőtt a migráció és a hosszú távú termékenységi trendek, továbbra is jelentős bizonytalanságot hordoznak.

Feltételezésünk, hogy ebben a kontextusban a mesterségesintelligencia- (MI-) alapú alkalmazások és az ezek motorját képező nagy nyelvi modellek (LLM-ek) megjelenése áttörést hozhat a tudományos előrejelzésekben. Az MI-alapú rendszerek predikciós képességének ígérete az, hogy képesek lehetnek a hagyományos statisztikai modelleknél komplexebb, nemlineáris összefüggések felismerésére, hozzájárulva a pontosabb előrejelzések elkészítéséhez és a hatékonyabb stratégiaalkotáshoz. Ugyanakkor felmerül a kérdés: az MI valóban paradigmaváltást hozhat-e például az igen komplex demográfiai előrejelzések területén, vagy csupán egy újabb bizonytalansági tényezőt jelent majd?

Tanulmányunkban egy kísérlet eredményeit mutatjuk be, amely egy magyarországi demográfiai előrejelzés példáján keresztül két, a tudományos munkában is elterjedt és gyakran használt MI-asszisztens prediktív analitikában való alkalmazhatóságát és korlátait vizsgálja. A demográfiai előrejelzések során szerzett tapasztalatok és a modellek működésére vonatkozó megfigyelések egyúttal általánosabb tanulságokkal is szolgálhatnak minden olyan terület számára, ahol a hagyományos előrejelző modelleket MI-alapú megközelítésekkel kívánják kiegészíteni a jövőben. A következőkben ezért áttekintjük a demográfiai előrejelzés modellezésének történeti fejlődését és az MI technológiai újdonságait, majd bemutatjuk kísérletünk módszertanát és az elért eredményeket.

## Szakirodalmi áttekintés

Szakirodalmi áttekintésünk két fő területre összpontosít. Egyrészt bemutatjuk a demográfiai előrejelzések módszertani fejlődését, másrészt áttekintjük az MI és a humán kutatói munka együttműködésének lehetőségeit, különös tekintettel a társadalomtudományi alkalmazásokra.

### A magyarországi népesség-előrejelzések történeti fejlődése

A magyarországi népesség-előrejelzések története a második világháború utáni időszakra nyúlik vissza. Az első próbálkozások még rendkívül egyszerű matematikai eljárásokon alapultak: a születések és halálozások számát állandónak tekintették a következő évre.<sup>4</sup> Ez a módszer azonban már rövid távon is jelentős felülbecs-

<sup>4</sup> Obádovics–Tóth 2023.

léshez vezetett, mivel a számítás során a babyboom idején mért kiugróan magas születésszámokat vették alapul, figyelmen kívül hagyva a demográfiai hullám természetét. A módszertani feltételezésből eredő hiba rámutatott ugyanakkor arra, hogy a teljes termékenységi arányszám (TTA) nem állandó, és a korstruktúra figyelmen kívül hagyása jelentős torzításhoz vezet.

E felismerés nyomán az 1960-as években paradigmaváltás történt: a leegyszerűsítő számításokat felváltotta az alkotóelem-módszer, más néven kohorsz-komponens modell (CCM).<sup>5</sup> Az új módszer már figyelembe vette a korstruktúrát, azaz a népességet korcsoportokra (ún. kohorszokra) bontva követte nyomon, és a három alapvető demográfiai komponens – születések, halálozások és migráció – változásának figyelembevételével mozdította előre az egyes korcsoportba tartozókat a következő életkorba. A modell alkalmazásához elengedhetetlen volt néhány új mutató bevezetése,<sup>6</sup> például a várható élettartam javulásának trendje, a korcsoportos termékenységi arányszámok (ASFR) és a migrációs korprofil. A módszer ezáltal már képes volt kezelni a babyboom és az azt követő hullámzások összetett hatásait.

A 20. század második felében a módszert tovább finomították. A fejlődés fő irányai a scenárióelemzés elmélyítése, a komponensek mikroszintű vizsgálata és a bizonytalanság kezelése volt. A legnagyobb előrelépést itt Habclicsek László munkássága hozta, aki a termékenység előrejelzéséhez eloszlástípusokat alkalmazott, ezzel szorosabb illeszkedést ért el.<sup>7</sup> A 2001-es népszámlálás után készült előrejelzések már scenáriókat alkalmaztak, de még determinisztikus módon: minden bemeneti paramétert (TTA, halandóság, migráció) egyetlen, rögzített értékkel vettek figyelembe. Így készült el a 2001-es népszámlálásra épülő prognózis, mely 2050-re 8,5–9 millió fő közötti népességet valószínűsített.<sup>8</sup> Bár rövid távon ezek a prognózisok viszonylag pontosnak bizonyultak, azt az illúziót keltették, hogy a jövő egyetlen kijelölt pályán halad, miközben a valóságban a népesség a szélsőértékek közötti teljes tartományban mozoghat.

A nemzetközi gyakorlatban ekkoriban jelent meg a probabilisztikus előrejelzés szemlélete, amely a bemeneti paraméterekhez nem fix értékeket, hanem valószínűségi eloszlásokat vett alapul, és így több ezer szimulációval számszerűsítette a jövőbeli bizonytalanságot.<sup>9</sup> A hazai előreszámítások ezzel szemben továbbra is

<sup>5</sup> A kohorsz-komponens modell, angolul *cohort component model* elméleti alapjait már a '20-as és '30-as években ismerték, Pascal K. Whelpton amerikai demográfus munkássága révén. (Whelpton 1928.)

<sup>6</sup> Fontosnak tartjuk továbbá megemlíteni Barsy Gyulát, akinek érdeme a halandósági táblák korszerűsítése; Acsádi Györgyöt, aki a népesség belső szerkezetének legfőbb úttörője; valamint Pallós Emilt, aki a számítási módszerek fejlesztéséért felelt. (Barsy 1959; Acsádi–Klinger 1965; Pallós 1973.)

<sup>7</sup> Szabó 1982.

<sup>8</sup> United Nations 2019; Eurostat 2022.

<sup>9</sup> United Nations 2005; Raftery et al. 2014.

determinisztikus scenáriókat alkalmaztak, vagyis egyetlen rögzített pályát vetítettek előre.

A Központi Statisztikai Hivatal (KSH) 2013-as előrejelzése<sup>10</sup> – amely a 2011-es népszámlálás adatain alapult,<sup>11</sup> és a 2013. évi 9,909 millió fős bázisból indult ki – három forgatókönyvet dolgozott ki 2060-ig.<sup>12</sup> Ez a prognózis egyértelműen jelezte, hogy még kedvező feltételek mellett is elkerülhetetlen a népesség csökkenése, ugyanakkor a migrációs paraméter alulbecslése rávilágított a modell érzékenységre. A következő meghatározó prognózis a KSH 2018-as hosszú távú előrejelzése volt, amely a 2017-es adatokból indult ki, és differenciált feltételezésekkel egészen 2100-ig tekintett előre. A KSH prognózisa 2050-re 8,4–9,2 millió fő közötti népességet, 2100-ra pedig 6,5–8,5 millió főt (alapváltozat szerint 7,4 millió főt) valószínűsített. Rövid távon ez a modell is pontosnak bizonyult, ugyanakkor két jelentős bizonytalansági tényező merült fel: egyrészt a születéskor várható élettartam 2020 és 2021 között átmenetileg meredeken csökkent, emiatt a tényleges halálozások száma az előre jelzettnél jóval magasabb lett, és ezt a sokkhatást a modell nem tudta kezelni; másrészt a migrációt ebben az esetben is alulbecsülték.<sup>13</sup> Láthatjuk tehát, hogy egy-egy, a népességváltozásra jelentős hatással bíró esemény nagymértékben növeli a modellezés bizonytalanságát.

A 2022. évi népszámlálás után Obádovics Csilla és Tóth G. Csaba újabb előrejelzést készített, amely négy determinisztikus forgatókönyvet (három országosan eltérő pálya és egy regionális, konvergáló vándorlás) dolgozott ki egészen 2050-ig. A prognózis tovább erősítette a korábbi számítások azon tézisének, miszerint a népesség tartósan csökken és öregszik. A demográfiai komponensek esetében ez a modell is fix értékekkel (alapforgatókönyv esetén 1,65-ös TTA-értékkel, magas termékenységnél 1,85-ös TTA-értékkel) és pozitív migrációs többlettel számolt. Újdonságot jelentett ugyanakkor, hogy a forgatókönyvek 0 migrációs változatát is elkészítették, valamint regionális dimenziót is bevontak a számításba. Ennek eredményeként az alapforgatókönyv 8,5 millió, a magas termékenységgű modell 8,8 millió, a migráció nélküli változat pedig 8,2 millió fős népességet vetített elő 2050-re.

Az általunk ismert legfrissebb előrejelzés<sup>14</sup> 2100-ig öt termékenységi (TTA 1,25–2,1) és két migrációs (0 és +13 439 fő/év migráció) forgatókönyvet kombinált. Ez a megközelítés lehetővé tette a szélsőséges scenáriók számszerűsítését is,

<sup>10</sup> Földházi 2013.

<sup>11</sup> A népesség-előreszámítások eredményeit két benchmarkat alapján értékelhetjük: a 2011-es népszámlálás szerint, mely 9 937 628 fős népességet rögzített, vagy a 2022-es népszámlálás 9 603 634 fős népessége alapján.

<sup>12</sup> Az alapváltozat szerint a TTA 1,60 körül stabilizálódik, és a népesség 7,9 millió főre csökken; a pesszimista változat 6,9 millió főt, az optimista 8,6 millió főt vetített előre.

<sup>13</sup> A modell az alapforgatókönyvben ~+10 000 fő/év nettó migrációval kalkulált, miközben a valós migrációs egyenleg 2022-től meghaladta az évi +25 000 főt.

<sup>14</sup> Gyorgyovich 2025.

és egyértelműen rámutatott arra, hogy a migráció kulcsszerepet játszik a népességfogyás ütemének mérséklésében, ugyanakkor még pozitív vándorlási egyenleg mellett sem állítható meg teljesen a csökkenés. A legpesszimistább változat így 3,9 millió fős népességet, míg a legoptimistább 9,6 millió főt valószínűsített a század végére.

Összességében elmondható, hogy az eddigi népesség-előrejelzések – Habcsek munkássága óta – a kohorsz-komponens módszerre épülnek, és a népszámlálások adatait használják bázisként. Valamennyi prognózis a 21. század hátralévő részében tartós népességcsökkenést jelez. A modellek jellemzően determinisztikusak, vagyis a bemeneti paraméterek alakulását rögzített, fix értékekkel kezelik. Ez a feltételezés rövid távon megbízható eredményeket ad, hosszabb távon azonban kevésbé képes kezelni a külső sokkhatásokat – például Covid19-járványt vagy a migrációs hullámokat. A tapasztalatok azt is mutatják, hogy a bizonytalansági tényezők közül a migráció a legingadozóbb komponens, mivel erősen függ a gazdasági válságoktól, globális konfliktusoktól és politikai eseményektől.<sup>15</sup> A bizonytalanságot hosszú távon növeli a gyermekvállalás időzítésének kiszámíthatatlansága is. További trendalakító tényezők például a járványok, legutóbb a Covid19-világjárvány okozott éles törést. A nemzetközi előrejelzésekben az adathiány is komoly bizonytalansági forrás, amely tovább növeli a hibahatárt. Mindezek mellett pedig fontos figyelembe venni a számítási időtávot is: míg a rövid távú szimulációk megbízhatóbbak, hiszen a már megszületett korosztályok életútja jobban modellezhető, addig a 2100-ig terjedő előrejelzések nagyobb bizonytalansággal terheltek. A történeti áttekintés tehát azt mutatja, hogy a demográfiai előrejelzések módszertana folyamatosan fejlődött, ugyanakkor a bizonytalansági tényezők kezelése továbbra is nyitott kérdés – ez például egy olyan részterület, ahol az MI bevonása új lehetőségeket kínálhat.

### **Módszertani eltérések a nemzetközi és hazai előrejelzésekben**

A jövő alakulása nem csupán hazai, de nemzetközi viszonylatban is meghatározó, ezért fontosnak tartjuk röviden kitérni a nemzetközi előrejelzésekre, illetve a hazai és nemzetközi számítások közötti különbségekre. Ahogyan az előzőekben bemutattuk, a kohorsz-komponens módszer az alapja az ENSZ (2004-től) és az Eurostat előrejelzéseinek is. A számítások eredményei azonban eltérnek egymástól, ami elsősorban módszertani különbségekből fakad. A különbségek egyik oka, hogy az Eurostat a tagállamok hivatalos adataira támaszkodik, és determinista modellezést alkalmaz, ezzel szemben az ENSZ globális, valószínűségi alapú előrejelzést készít, amely a történelmi változékonyságot is beépíti. Az eltérések másik fő oka a migrációs komponens eltérő kezelése. Az ENSZ hosszú távon jellemzően negatív nettó migrációs egyenleggel számol, míg az Eurostat a jövőre nézve jellemzően pozitív

<sup>15</sup> Gyorgyovich 2025; Földházi 2013; KSH 2025.

egyenleggel kalkulál. Fontos különbség továbbá a hirtelen társadalmi-gazdasági sokkok beépítése, kezelése. Az ENSZ beépíti számításaiba ezeket a változásokat – például a Covid19-járvány hatását –, míg az Eurostat kizárja azokat a fő trendekből, így a Covid19-járvány esetében a halálozási rátákat a járvány előtti szintre állította vissza.

Az eltérő módszertani megközelítések eredményeként az ENSZ becslései<sup>16</sup> rendszerint pesszimistábbak: Magyarország esetében 2054-re 8,616 millió, 2100-ra 7,469 millió fős népességet prognosztizál,<sup>17</sup> míg az Eurostat (EUROPOP2023)<sup>18</sup> mérsékeltebb csökkenést feltételez, és 2100-ra 9,23 millió főt vetít előre. A KSH 2018-as prognózisa<sup>19</sup> 7,89 millió fős népességet jelez 2100-ra, ez a becslés a két nemzetközi szervezet által kalkulált értékek között helyezkedik el. A három intézmény előrejelzései közötti különbségek ugyancsak jól érzékeltetik a szakpolitikai cselekvést megalapozó alapvető bizonytalanságokat.

### A kutatói szerepkör alakulása és a mesterségesintelligencia-eszközök használata

Az előzőekben bemutatuk, hogy a demográfiai előrejelzések hosszú távon jelentős bizonytalanságokkal terheltek, amelyek kezelésében új lehetőségeket kínálnak az MI eszközei. A generatív MI 2022 után, a ChatGPT 3.5-ös modelljének megjelenését követően gyorsan elterjedt, és azóta már több száz millió ember hagyatkozik folyamatosan a nagy nyelvi modellekre épülő asszisztensek támogatására.<sup>20</sup> Ideális esetben ezek az alkalmazások az emberi intelligencia (problémamegoldó képesség) és az MI együttműködésén alapulnak. A szakirodalom ezt kiterjesztett intelligenciának (*augmented intelligence*) nevezi, amelynek lényege, hogy az MI nem önállóan dönt vagy hoz létre tartalmat, hanem a kutatóval közösen alkot, miközben az irányítás továbbra is a humán intelligenciánál marad. Mindez rendkívül fontos akkor, amikor a feladatot definiáló személy jobban ismeri a kontextust, és az MI által bizonytalanul meghatározott megoldások esetében a felhasználó a saját tapasztalata alapján tud végső döntéseket meghozni – ezzel a két intelligencia nemcsak kiegészíti, hanem erősíti is egymást.<sup>21</sup>

A 2022–2025 közötti időszakban a legtöbb multinacionális platformszolgáltató saját nyelvi modellt és azokra épülő csevegőasszisztentst fejlesztett, de világszerte az OpenAI ChatGPT-je, a Google Gemini és a DeepSeek váltak a legelterjedtebbé.<sup>22</sup> Magyarországon a keresési adatok alapján a ChatGPT és a Gemini bizonyult

<sup>16</sup> ENSZ-becslések: <https://population.un.org/wpp/downloads?folder=Standard%20Projections&group=Most%20used> (médium változat).

<sup>17</sup> United Nations 2024.

<sup>18</sup> Eurostat 2023.

<sup>19</sup> KSH: [https://www.ksh.hu/docs/hun/eurostat\\_tablak/tabl/tps00002.html](https://www.ksh.hu/docs/hun/eurostat_tablak/tabl/tps00002.html)

<sup>20</sup> Chatterji et al. 2025 szerint a ChatGPT felületét hetente átlagosan 700 millió felhasználó látogatja.

<sup>21</sup> Ahdadou et al. 2024.

<sup>22</sup> Sarkar 2025 alapján például megállapítható az említett sorrend.

az elmúlt időszakban a legnépszerűbbnek,<sup>23</sup> ezért kísérletünkben e két szoftvert választottuk a teszteléshez. Mindkettő klasszikusan nagy nyelvi modellként indult, tehát olyan rendszer fut a csevegőablak háttérében, amely szövegek értelmezésére, feldolgozására és új szövegek létrehozására lett kifejlesztve és betanítva. Ugyanakkor a ChatGPT 2023 végén, a Gemini pedig 2024 februárjában már az úgynevezett Mixture of Experts (MoE) architektúrát használta a válaszok létrehozására. Ez a megoldás lehetővé tette, hogy a rendszerek a kapott feladatokat lebontsák, és a különböző részfeladatokat más és más almodellnek (a feladat szakértőjének) delegálják, így a rendszerek már kvantitatív modellezésre és statisztikai számítások elvégzésére is alkalmassá váltak.

A szakirodalmi források ugyanakkor felhívják a figyelmet arra, hogy az MI-asszisztensek és a nagy nyelvi modellek már jóval a MoE megjelenése előtt is támogatták a társadalomtudományi kutatásokat. A leggyakrabban említett kutatási és publikációs feladatok közé tartozik például a szekunder kutatás elvégzése vagy támogatása, a megírt tudományos közlemények nyelvi lektorálása, valamint a szakirodalom feldolgozása (akár korábbi tanulmányok elemzése, akár a hálózatos modellezésnek köszönhetően a szakirodalomban megjelent tanulmányok közötti kapcsolatok feltárása). Mindezek mellett a kvalitatív primer adatgyűjtést és adatfeldolgozást a nagy nyelvi modellek természetüknél fogva is magas szinten tudják támogatni: felismerik a szavak közötti hasonlóságokat, rövidíteni, kivonatolni tudják az elhangzott szövegeket, képesek lehetnek a kódolásra vagy a témák feltárására, és alkalmassá tudják tenni az interjúkat arra, hogy kvantitatív módon is lehessen elemezni azokat.<sup>24</sup> Ezen lehetőségek mellett 2023 végétől, illetve 2024 elejétől már kvantitatív adatelemzésre is használhatók az említett MI-asszisztensek, valamint a folyamatosan javuló programozási tudásuknak köszönhetően az adatelemző képességük is permanensen fejlődik. A generatív MI-eszközök adatelemző képességének vizsgálata ezáltal új terület a kutatók számára is, bár találhatunk már néhány tanulmányt, amelyek eltérő struktúrában és különböző fókuszokkal vizsgálják a kialakult lehetőségeket. Schwartz<sup>25</sup> például egy adatbázis leíró statisztikai elemzésére mutat példát, amelyhez a ChatGPT felületét alkalmazta, vagy például Prandner<sup>26</sup> és szerzőtársai különböző kísérleti elrendezésben próbálták egy már elkészült tudományos publikáció mögött álló munkát az MI-asszisztensnek delegálni. A jelen tanulmányban bemutatott kísérleti elrendezés Prandnerék megol-

<sup>23</sup> A Google Trends weboldal keresési gyakorisági értékeit vettük alapul az elmúlt egy évet vizsgálva, ahol a legfrissebb, 2025. októberi értékek alapján arányaiban a ChatGPT-re jutó 100 kereséshez képest a Geminire 9, a DeepSeekre pedig 1 keresés jut. Lásd részletesen a trends.google.com címen az aktuális összehasonlításokat.

<sup>24</sup> Beale 2025; Jauhainen–Toppari 2025.

<sup>25</sup> Schwartz 2025.

<sup>26</sup> Prandner et al. 2025.

dásához hasonló, mégis annyiban eltérő, hogy a rendszerek érzékenységét és az eltérő MI-asszisztensek közötti különbségeket is megvizsgáljuk.

A generatív MI integrálása az akadémiai kutatásba gyorsan terjed, és a kutatási folyamatok különböző szakaszait érinti.<sup>27</sup> A technológiai változás a meglévő kutatási módszerek újraértékelését teszi szükségessé, és a kutatók körében az MI képességeinek és korlátainak alaposabb megértését igényli. Ugyanakkor mindez etikai kérdéseket is felvet – az adatok torzításától a szerzőségig és az átláthatóságig –, ezért a kutatóknak nemcsak el kell sajátítaniuk ezen eszközök használatát, hanem kritikus megértést is ki kell alakítaniuk a rendszerek alapjául szolgáló mechanizmusokról és a kutatási eredményekre gyakorolt lehetséges hatásairól.

A generatív MI tehát új távlatokat nyit a társadalomtudományi kutatásokban: a nagy nyelvi modellek már nemcsak kvalitatív feladatokban, hanem kvantitatív szimulációkban is képesek támogatni a kutatói munkát, és ezáltal meg tudják valósítani az említett kiterjesztett intelligenciát. A következőkben azt mutatjuk be, milyen módon építettük be ezeket a lehetőségeket saját módszertani megközelítésünkbe a demográfiai előrejelzés vizsgálata során.

## Módszertan

Tanulmányunkban egy olyan kísérlet eredményeit mutatjuk be, melynek célja az MI – azon belül is az LLM-ek – prediktív analitikában való alkalmazhatóságának és korlátainak feltárása a demográfiai előrejelzés komplex példáján keresztül. A demográfiai előrejelzések terén tapasztalható – a szakirodalmi részben már széleskörűen bemutatott – módszertani sokszínűség és bizonytalanság, valamint az MI gyors elterjedése okán felmerül a kérdés, hogy az MI valóban paradigmaváltást hoz-e a demográfiai vagy más jellegű előrejelzések területén, vagy csupán egy újabb bizonytalansági tényezőt jelent az elemzés során. E központi kérdés által vezérelve egy kísérleti eljárást dolgoztunk ki, hogy megfigyeljük a modellek működését és alkalmazhatóságát.

### **Kísérleti elrendezés és előzetes feltevéseink**

A kísérlet során két nagy nyelvi modellt – a ChatGPT 5 Plus-t és a Gemini 2.5 Pro-t – teszteltünk. Feladatuk Magyarország népességének várható alakulására vonatkozó rövid távú (2033-ig terjedő) és hosszú távú (2100-ig terjedő) előrejelzés elkészítése volt.

---

<sup>27</sup> Ganguly et al. 2025.

Ehhez egy négy szintű prompt-mátrixot alakítottunk ki (lásd melléklet), amely különböző részletettségű és strukturáltsággal határozta meg a modellek számára az elvégzendő feladatot:<sup>28</sup>

1. **Strukturálatlan szint:** a modellek a legkevesebb inputot kapták, a módszertan, a bemeneti adatok és belső számítások szabadon választhatók voltak.
2. **Elnagyolt szint:** a modellek táblázat formájában kapták meg a bemeneti demográfiai adatokat (a KSH 2023. évközepe népmozgalmi adatait, valamint az ENSZ várható élettartam-prognózisának alapváltozatát), azonban a módszertan és a számítás logikája továbbra sem volt megkötve.
3. **Közepesen definiált szint:** az elnagyolt szinttel azonos bemeneti adatok mellett a fő demográfiai dimenziókat (TTA, migrációs értékek) is meghatároztuk, amely megegyezett a referenciatanulmányban vizsgált értékekkel, ugyanakkor a belső számítás mechanizmusa rugalmas maradt az asszisztens számára.
4. **Teljesen strukturált szint:** a közepesen definiált szinttel azonos bemeneti adatok mellett a modellek (a referenciaszimulációhoz igazodó) minden szükséges paramétert, a kohorsz-komponens modell pontos logikáját és irányelvét is megkapták, valamint a kimenet formátuma (táblázat, CSV, vizualizáció) is szigorúan rögzített volt.

Minden szinten három forgatókönyv (pesszimista, alap-, optimista) elkészítését kértük, a harmadik és negyedik szinten fix TTA-értékek (1,25, 1,65 és 1,85), valamint kétféle migrációs paraméter (migráció1: 0 fő/év, migráció2: +13 439 fő/év) figyelembevételével. Az előrejelzéseket két időhorizonton futtattuk: 2033-ig és 2100-ig.

A modellek kiválasztásánál fontos szempont volt, hogy a legfrissebb, előfizetéses verziókat használjuk, feltételezve azt, hogy a precizitás modellről modellre javul. Emellett tudatosan olyan eszközöket választottunk, amelyek széles körben elérhetők, és amelyeket nemcsak kutatók, hanem hétköznapi felhasználók is alkalmaznak komplex feladatok megoldására. A demográfiai előrejelzés esettanulmányként azért is volt kézenfekvő, mert az eredményeket a szakirodalomban is bemutatott, 2025-ben megjelent, kohorsz-komponens számításra alapuló előrejelzés adataival tudtuk validálni. Így nemcsak arról kaphattunk képet, hogy mennyire tűnik a kapott válasz egy kutató számára hitelesnek, hanem hogy mennyire pontos a számítási folyamat eredménye.

Előzetes feltevéseink szerint a prompt strukturáltságának növekedésével az előrejelzési hiba, vagyis a referencia-előrejelzéstől való eltérés szignifikánsan csökken, tehát minél pontosabban tudjuk irányítani az MI-asszisztent, annál precízebben

<sup>28</sup> A promptokat magyar nyelven írtuk meg, mivel az új MoE architektúra csökkenti a nyelvi kötöttségeket: a rendszer először nyelvfeldolgozási szakértőhöz irányítja a parancsokat, majd angolul történik a feladat elvégzése, végül pedig a válasz egy nyelvgeneráló szakértő modullal kerül visszafordításra. Az angol nyelvű promptolás ezáltal inkább a lépések számát csökkenti, de nem feltétlenül jár kisebb hibalehetőséggel.

fogja a tényleges és elvárt szimulációt megvalósítani, ami növeli a modellek átláthatóságát és elszámoltathatóságát. További feltételezésünk volt, hogy a rövid távú (2033-ig terjedő) előrejelzések pontosabbak, mint a hosszú távú (2100-ig terjedő) előrejelzések, ami – amennyiben így van – félrevezető lehet a kutatói gyakorlatban.

A kísérletet 2025. július–szeptember hónapban végeztük el, modellenként 48 futtatással (2 időhorizont  $\times$  4 prompt-szint  $\times$  6 forgatókönyv). Az asszisztenseket alapbeállításban és alternatív üzemmódokban (ChatGPT esetén „Thinking” módban, Gemini esetében „Flash” módban) is teszteltük. Elemzésünkben ezáltal nemcsak az előrejelzések pontosságát, megbízhatóságát és trendkövetési képességét vizsgáltuk, hanem a paraméterválasztási mechanizmust és a kvalitatív magyarázatadási képességet is, amelyek kulcsfontosságúak a csevegőasszisztensek kutatási feladatokban való alkalmazhatósága szempontjából.

Az alábbiakban, ezen tényezőkre építve, a kísérlet főbb eredményeit közöljük.

## Eredmények

Eredményeinket három fő szempont – pontosság, módszertani hűség és alkalmazhatóság – mentén mutatjuk be.

### **A modellek robusztussága és a paraméterválasztás torzítása**

A kísérlet tervezése során a módszertani részben bemutatott 48 futtatást céloztunk meg modellenként, a tényleges tesztelést követően azonban mind a két szoftver összesen 42 futtatást végzett el. Azon a szinten ugyanis, ahol a modellek a legkisebb kötöttséget kapták (strukturálatlan szint), sem a ChatGPT, sem a Gemini nem készített migráció nélküli forgatókönyvet. Ez önmagában fontos módszertani tanulság: a nyelvi modellek vélhetően nehezen kezelik a tagadó, a „nem létezésről” szóló feltételezéseket, és mindenáron valamilyen választ akarnak adni. Esetünkben ez a migrációhoz való ragaszkodásban jelent meg, ami a prediktív analitika más területein is korlátozhatja az alkalmazhatóságukat, vagy legalábbis precízebb megfogalmazást igényel a prompt kialakításakor.

Elsőként a paraméterválasztást vizsgáltuk (1. táblázat). Azokon a szinteken, ahol az MI-asszisztensek szabadon választhatták meg a bemeneti paramétereket, jól érzékelhető a modellek bizonytalansága. Ennek oka részben az, hogy a modellek a szabad paraméterválasztás során külső forrásokra hagyatkoztak: képesek a nyíltan elérhető webes keresési találatokból meríteni, azonban a hivatalos adatbázisok elérése során problémába ütköznek. A kiadványokra és cikkekre támaszkodás így jelentősen torzítani tudta a kezdeti paraméterválasztást. Ez azt eredményezte, hogy a számítási folyamat már a kiindulópontnál téves vagy túlzó volt, a végeredmény hibáját pedig a számítási modell pontatlansága tovább erősítette.

1. táblázat: A ChatGPT és a Gemini paraméterválasztása az egyes prompt-szinteken

ChatGPT 5 Plus	Szint	Strukturálatlan		Elnagyolt		Közepesen definiált		Strukturált	
	Időhorizont	2033	2100	2033	2100	2033	2100	2033	2100
	TTA								
	Pesszimista	1,25	1,25	1,4	1,35	1,25			
	Alap	1,45	1,7	1,55	1,51	1,65			
	Optimista	2,1	1,9	1,75	1,75	1,85			
	Migráció (fő/év)								
	Pesszimista	-5 000	-10 000	(+ 30 000	(+ 20 000	(+ 13 439			
	Alap	(+) 14 000	(+) 20 000						
	Optimista	(+) 25 000	(+) 35 000						

Gemini 2.5 Pro	Szint	Strukturálatlan		Elnagyolt		Közepesen definiált		Strukturált	
	Időhorizont	2033	2100	2033	2100	2033	2100	2033	2100
	TTA								
	Pesszimista	1,4	1,4	1,4	1,3	1,25			
	Alap	1,5–1,6	1,7	1,56	1,51	1,65			
	Optimista	1,75	1,9	1,7	1,8	1,85			
	Migráció (fő/év)								
	Pesszimista	-10 000	-20 000	(+ 26 000	(+ 25 000	(+ 13 439			
	Alap	(+) 5 000	-5 000						
	Optimista	(+) 15 000	(+) 5 000						

Forrás: Századvég-szerkesztés

A nagyfokú szabadság különösen a ChatGPT esetében vezetett szélsőséges kiemethez: a strukturálatlan szinten, optimista forgatókönyvben, migrációval számolva például közel 11 millió fős népességet vetített előre 2100-ra. A Gemini ezzel szemben konzervatívabb paraméterválasztást alkalmazott, így kevésbé szélsőséges eredményeket adott.

A migrációs komponens mindkét modell esetében kritikus tényezőnek bizonyult. A ChatGPT túlérzékenyen reagált, és következetesen 1-2 millió fővel magasabb népességszámot vetített előre a referenciaértékhez képest. A Gemini esetében ezzel szemben mérsékelt hatás mutatkozott, de következetesen pozitív irányú. A migráció nélküli forgatókönyvek mindkét modellenél gyorsabb népességfogyást vetítettek előre, ami összhangban van a hagyományos módszerek azon megállapításával, miszerint a migráció hosszú távon képes mérsékelni a fogyást, de nem fordítja meg a trendet.

## Pontosság, módszertani hűség

2. táblázat: Az egyes forgatókönyv-kimenetek eredményei a referenciaértékekhez viszonyítva

Év	Szoftver	Prompt	Migráció nélkül			Migrációval		
			Pesszi- mista	Alap	Opti- mista	Pesszi- mista	Alap	Opti- mista
2033	ChatGPT	Strukturá- latlan	n.a.			-1,12%	0,00%	0,83%
		Elnagyolt	0,25%	-0,47%	-0,12%	2,12%	1,37%	1,72%
		Közepesen definiált	-0,58%	-1,62%	-1,64%	-1,43%	-1,43%	-1,44%
		Strukturált	-0,70%	-0,92%	-1,04%	-0,67%	-0,89%	-1,01%
	Gemini 2.5 Pro	Strukturá- latlan	n.a.			-2,24%	-0,95%	0,12%
		Elnagyolt	-0,13%	-1,05%	-1,30%	1,18%	0,23%	-0,03%
		Közepesen definiált	2,90%	2,50%	2,17%	2,70%	2,29%	1,95%
		Strukturált	0,33%	1,02%	1,66%	0,26%	0,93%	1,57%
2100	ChatGPT	Strukturá- latlan	n.a.			19,56%	34,49%	40,02%
		Elnagyolt	-1,44%	-18,75%	-13,16%	11,43%	-6,90%	-2,48%
		Közepesen definiált	9,32%	6,02%	4,73%	10,37%	7,79%	6,71%
		Strukturált	-13,02%	-11,66%	-11,16%	-7,92%	-7,15%	-6,86%
	Gemini 2.5 Pro	Strukturá- latlan	n.a.			9,26%	-2,09%	-3,81%
		Elnagyolt	37,75%	2,47%	-4,14%	25,51%	-3,30%	2,74%
		Közepesen definiált	43,94%	12,59%	2,26%	26,67%	2,33%	-6,09%
		Strukturált	33,87%	10,55%	3,26%	19,52%	2,48%	-4,05%

Forrás: Századvég-szerkesztés

A 2. táblázatban az egyes forgatókönyvekhez tartozó relatív eltéréseket ábrázoltuk a validáló szimulációk eredményeihez viszonyítva. Az értékek színe minél vörösebb, annál inkább túlbecsül a modell a referenciaértékhez viszonyítva, és minél kékebb, annál inkább alulbecsül. Az eredmények jól mutatják a hosszú távon jelentkező bizonytalanságot: rövid távú (2033-ig terjedő) előrejelzéseknél az MI-aszisztensek  $\pm 2$  százalékos hibahatárral illeszkedtek a referenciaértékekhez, hosszú

távon azonban a bizonytalanság jelentősen megnő, egy kevésbé pontos utasítás vagy forgatókönyv esetén meghaladhatja a 30 százalékot is.

A ChatGPT rövid távon hajlamos volt az alulbecslésre, hosszú távon azonban szélsőségesen ingadozott: kevésbé kötött prompt esetén jellemzően túlzottan optimista, míg kötöttebb prompt esetén túlzottan pesszimista kimeneteket adott. Ez arra utal, hogy a modell erősen prompt-érzékeny. A Gemini ezzel szemben rövid és hosszú távon is inkább a felülbecslésre hajlott, és eredményei kevésbé függték a prompt részletezettségétől. Ez azt mutatja, hogy a modell inkább forgatókönyv-érzékeny, vagyis a kimenetek itt inkább a szcenárió paramétereitől függték, mint a prompt kidolgozottságának szintjétől.

Fontos módszertani tanulságot hozott a modellek belső beállításainak (üzem-módjainak) vizsgálata is. A ChatGPT „Thinking” módja kiegyenlítő stratégiát alkalmazott: a pesszimista pályát felhúzta, az optimistát visszafogta. A Gemini „Flash” módja ezzel szemben már a kiinduló adatok értelmezésében is torzítást mutatott, ami így teljesen más irányú számítást eredményezett. Ez igazolja, hogy az előrejelzés minőségét nemcsak a bemeneti paraméterek és a prompt részletezettsége, hanem a modellek belső működési módjai is befolyásolják, és egyáltalán nem mindegy, hogy a kutatónak van-e lehetősége megváltoztatni ezeket a beállításokat.

Az egyes forgatókönyvek eloszlását, valamint referenciaértéktől való eltérését követően a módszertani hűséget is megvizsgáltuk a kapott válaszok elemzésével. Egy előrejelzés során ugyanis önmagában nem elegendő a statisztikai pontosság, a számítási logika helyes alkalmazása is éppen annyira fontos. E téren azt tapasztaltuk, hogy az MI-asszisztensek minden esetben megjelölték a helyes számítási módszert, alkalmazni azonban csak részben tudták. Strukturálatlan szinten például a modellek makroszintű népességmérleg-modellt alkalmaztak, amely nem kezelte a korstruktúrát, így rövid távon jó illeszkedést mutattak, hosszú távon azonban jelentősen romlott a pontosságuk. Elnagyolt szinten a ChatGPT a Leslie-mátrix-alapú kohorsz-komponens modellt alkalmazta, de a paramétereket mereven kezelte: a termékenységet és halálozást állandónak vette, és nem vette figyelembe a várható élettartam javulásának trendjét. A ChatGPT esetében a közepesen definiált szint bizonyult a legközelebbinek a szakirodalmi standardhoz: itt a modell lineárisan futtatta fel a TTA-t 2033-ig, figyelembe vette a halandóság javulását és a migrációs korprofil súlyozását. A teljesen strukturált szinten, paradox módon, a modellek olyannyira igyekeztek lekövetni a számítási logikát, hogy közben a bizonytalanság enyhén emelkedett.

Fontos megjegyeznünk, hogy a rövid és hosszú távú előrejelzéseket érdemes együtt értelmezni. Előfordult ugyanis, hogy egy prompt rövid távon gyengébben teljesített (például a közepesen definiált szinten), de hosszú távon pontosabb eredményt adott. Ez arra utal, hogy a szoftver a számítási mechanizmust pontosabban követte, mint azokban az esetekben, amikor rövid távon jó illeszkedést mutatott, de hosszú távon jelentősen eltért a referenciaértékektől (strukturálatlan szint).

A Gemini esetében ezzel szemben a teljesen strukturálatlan és a leginkább strukturált prompt adta a relatíve legjobb eredményeket. Úgy tűnik, hogy amikor csak részben segítettük a modellezést, az kevésbé volt célravezető. Ugyanakkor a szoftvernél kevésbé volt érzékelhető a függőség a prompt felépítésétől, mint a ChatGPT-nél.

## Következtetések és módszertani ajánlások

Vizsgálatunk a demográfiai előrejelzés példáján keresztül számos tanulsággal szolgált a nagy nyelvi modellekre épülő MI-asszisztensek prediktív analitikában való alkalmazásának lehetőségeiről és rejtett kockázatairól. Kutatásunk megerősítette, hogy a kipróbált két MI-asszisztens képes már komplex előrejelzési feladatok ellátására, de jelenlegi formájukban elsősorban kiegészítő eszközként alkalmazhatók.

Rövid távon a modellek megbízható eredményt adtak, hosszú távon azonban jelentősen nőtt a bizonytalanság, amelynek hátterében a paraméterválasztás és számítási logika állhat. Fontos tanulság, hogy a rövid és hosszú távú előrejelzéseket együtt kell értelmezni: előfordult, hogy egy prompt 2033-ig pontosnak tűnt, de 2100-ra szétesett, míg más esetben a rövid távú előrejelzés gyengébb illeszkedése mellett a hosszú távú bizonyult stabilabbnak. Ez különösen veszélyes lehet egy kevésbé jártas kutató számára, aki a rövid távú pontossága alapján azt gondolhatja, hogy a hosszabb távú számítást is helyesen végezte el a rendszer.

A migrációs komponens mindkét modell esetében kritikus tényezőnek bizonyult, összhangban a szakirodalomban jelzett bizonytalanságokkal; ugyanakkor a Gemini mérsékeltebb hatást mutatott, mint a ChatGPT. A forgatókönyvek eltérései részben igazolták kiinduló feltételezésünket, miszerint a prompt strukturáltságának szigorúsága jelentősen befolyásolja az előrejelzések pontosságát és stabilitását. Ugyanakkor paradox módon a teljes strukturáltság sem bizonyult a leghatékonyabbnak. Eredményeink alapján a ChatGPT inkább prompt-érzékeny, míg a Gemini forgatókönyv-érzékeny.

A kísérlet azonosított számunkra olyan korlátokat, amelyek miatt az LLM-alapú MI-asszisztensek jelenleg még nem képesek kiváltani a hagyományos, kutatók által validált matematikai modellezéseket. Ezek között említjük meg például a migrációs komponens kezelésének instabilitását, a paraméterválasztás átláthatatlanságát, a beállítás hatásait, valamint a tagadó, vagyis a nem létező, nullával egyenlő elemek feltételezésének kezelési korlátait. Ugyanakkor az is látszik, hogy nagyobb szabadság mellett az asszisztensek olyan tényezőket is bevonhatnak az előrejelzések alakításába, amelyeket a hagyományos modellezések nem tartalmaznak, ezzel is árnyalva a kutató számára kialakuló jövőképet.

Az MI-asszisztensek hatékony alkalmazásához javasoljuk egy közepesen definiált vagy strukturált prompt-sablon használatát, amely mindkét modell esetében

relatíve jobban teljesített. A magas bizonytalansági faktorról rendelkező paramétereket – például a mi esetünkben a migrációs komponenst – külső, számszerűsített forrásból javasoljuk beépíteni a promptba, ezzel elkerülve a modell szabad paraméterválasztásából eredő torzítását. Célszerű továbbá minden esetben a modelltől kérni a számítási logika bemutatását, hogy ellenőrizhető legyen a módszer helyes alkalmazása, valamint javasoljuk a modell kimenetének összevetését validáló eredményekkel – ahol elérhető –, és a különbségek magyarázatának kikérését, ami a későbbi prompt-finomítást segítheti.

Jelen tanulmányban az eredmények elemzését egyszerűsítve, pontszerűen végeztük el, a 2033-as és a 2100-as értékekre fókuszálva. Ez lehetővé tette, hogy a főbb trendeket és a modellek működésének sajátosságait bemutassuk, ugyanakkor számos további vizsgálati lehetőség nyitva maradt. További kutatási irányt jelenthet a modellek időrosos stabilitásának vizsgálata, a paraméterek érzékenysége további tesztelése, valamint a különböző beállítások hatásának szisztematikus összehasonlítása.

Összességében tehát jelen munkánk egy első kísérlet volt arra, hogy feltárjuk a nagy nyelvi modellek alkalmazhatóságát a demográfiai előrejelzésekben. Úgy látjuk, hogy az MI-asszisztensek hasznos kiegészítői lehetnek kvantitatív modellezéseknek is, például a demográfiai előrejelzéseknek, különösen a trendek gyors feltérképezésében, hipotézisek meghatározásában, esetlegesen tesztelésében is, valamint alternatív scenáriók generálásában, vagy akár további, a folyamatokat alakító tényezők feltárásában. Ugyanakkor nem képesek feloldani a hosszú távú bizonytalanságokat, sőt, a látszólagos pontosság illúzióját kelthetik. Ezáltal az MI-alapú előrejelzések csak akkor lehetnek valóban hatékonyak, ha a felhasználó tisztában van azzal, hogy a modell számítási logikát hajt végre, de nem helyettesíti a szakterületi tudást és a bizonytalanság humán intelligenciával történő kezelését.

## Irodalom

- Acsádi, G. – Klinger, A. 1965: *Magyarország népesedése a két világháború között*. KSH Népeségtudományi Kutató Intézet.
- Ahdadou, M. – Aajly, A. – Tahrouch, M. 2024: Unlocking the potential of augmented intelligence: a discussion on its role in boardroom decision-making. *International Journal of Disclosure and Governance*, 21. évfolyam, 433–446. <https://doi.org/10.1057/s41310-023-00207-2> (letöltve: 2025. 11. 14.)
- Barsy, Gy. 1959: *A halandósági táblák szerkezete és alkalmazása*. Központi Statisztikai Hivatal.
- Bauer, B. – Nagy, M. T. 2021: A népesség elöregedésének társadalmi hatásai Magyarországon. In: Pillók, P. – Stefkovics, Á. – Hortay, O. (szerk.) *Századvég Riport 2021*. Budapest, Századvég, 405–432.
- Beale, R. 2025: Adapting University Policies for Generative AI: Opportunities, Challenges, and Policy Solutions in Higher Education. *arXiv preprint arXiv:2506.22231*. <https://doi.org/10.48550/ARXIV.2506.22231> (letöltve: 2025. 11. 14.)
- Chatteji, A. – Cunningham, T. – Damin, D. – Hitzig, Z. – Ong, C. – Shan, C. – Wadman, K. 2025: *How People Use ChatGPT*. <https://www.nber.org/papers/w34255> (letöltve: 2025. 10. 01.)
- Európai Bizottság 2023: *A migráció átfogó megközelítésére vonatkozó cselekvési terv* [dokumentum]. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A52023DC0577> (letöltve: 2025. 11. 14.)
- Eurostat 2023: *Population projections – EUROPOP2023*. Eurostat. [https://ec.europa.eu/eurostat/databrowser/view/proj\\_23np/default/table?lang=en&category=proj.proj\\_23n](https://ec.europa.eu/eurostat/databrowser/view/proj_23np/default/table?lang=en&category=proj.proj_23n) (letöltve: 2025. 11. 14.)
- Eurostat: *Population projections (Népesség-előrejelzések)*. Eurostat. <https://ec.europa.eu/eurostat/web/population-demography/population-projections> (letöltve: 2025. 11. 14.)
- Földházi, E. 2013: Magyarország népességének várható alakulása 2060-ig: A legújabb népesség-előreszámítás eredményei. *Korfa*, 13. évfolyam, 4. <https://demografia.hu/kiadvanyokonline/index.php/korfa/article/view/730/194> (letöltve: 2025. 11. 14.)
- Ganguly, A. – Johri, A. – Ali, A. – McDonald, N. 2025: Generative artificial intelligence for academic research: Evidence from guidance issued for researchers by higher education institutions in the United States. *AI and Ethics*, 5. évfolyam, 4, 3917–3933. <https://doi.org/10.1007/s43681-025-00688-7> (letöltve: 2025. 11. 14.)
- Gyorgyovich, M. 2025: Magyarország demográfiai jövőképe 2100-ig; forgatókönyvek, kihívások, szakpolitikai megfontolások. In: Stefkovics, Á. – Pillók, P. (szerk.) *Századvég Riport 2025*. Budapest, Századvég, 131–146.
- Jauhiainen, J. S. – Toppari, A. 2025: Generative Artificial Intelligence and Agents in Research and Teaching. *arXiv preprint arXiv:2508.16701*. <https://doi.org/10.48550/ARXIV.2508.16701> (letöltve: 2025. 11. 14.)
- KSH 2025: *Népesedési Világnap 2025* [jelentés]. <https://www.ksh.hu/s/kiadvanyok/nepesedesi-vilagnap-2025/index.html> (letöltve: 2025. 11. 14.)
- KSH: *Népesség-előreszámítások: A KSH 2018-as prognózisa (2018–2100)* [adattábla]. [https://www.ksh.hu/docs/hun/eurostat\\_tablak/tabl/tps00002.html](https://www.ksh.hu/docs/hun/eurostat_tablak/tabl/tps00002.html) (letöltve: 2025. 11. 14.)

- Obádovics, Cs. – Tóth G., Cs. 2023: A magyarországi régiók népességének előreszámítása 2050-ig. *Statisztikai Szemle*, 101. évfolyam, 9, 763–792. <https://doi.org/10.20311/stat2023.09.hu0763> (letöltve: 2025. 11. 14.)
- Pallós, E. 1973: Magyarország népességének előreszámítása (1972–2000). Budapest. *KSH NKI Közleményei*, 36, 199.
- Prandner, D. – Wetzelhütter, D. – Hese, S. 2025: ChatGPT as a data analyst: An exploratory study on AI-supported quantitative data analysis in empirical research. *Frontiers in Education*, 9, 1417900. <https://doi.org/10.3389/educ.2024.1417900> (letöltve: 2025. 11. 14.)
- Raftery, A. E. – Li, N. – Gerland, P. 2014: Bayesian probabilistic population projections for all countries. *Proceedings of the National Academy of Sciences*, 111. évfolyam, 38, 13802–13807.
- Ritchie, H. – Roser, M. – Ortiz-Ospina, E. 2024: UN Population Prospects 2024 Revision (ENSZ népesség-előrejelzés 2024 felülvizsgálat). *Our World in Data*. 2024. július 11. <https://ourworldindata.org/un-population-2024-revision> (letöltve: 2025. 11. 14.)
- Sarkar, S. 2025: Are AI Chatbots Replacing Search Engines? *Onelittleweb*. 2025. április 22. <https://onelittleweb.com/data-studies/ai-chatbots-vs-search-engines/> (letöltve 2025. 11. 14.)
- Schwarz, J. 2025: The use of generative AI in statistical data analysis and its impact on teaching statistics at universities of applied sciences. *Teaching Statistics*, 47. évfolyam, 2, 118–128. <https://doi.org/10.1111/test.12398> (letöltve: 2025. 11. 14.)
- Szabó, K. 1982: *A magyar népesség-előreszámítások néhány módszertani kérdése*. <https://www.demografia.hu/kiadvanyokonline/index.php/kutatasijelentesek/article/view/1941>
- United Nations, Department of Economic and Social Affairs, Population Division: *Az ENSZ népességbecslések és -előrejelzések módszertana* [módszertani dokumentum]. <https://population.un.org/wpp/methodology> (letöltve: 2025. 11. 14.)
- United Nations, Department of Economic and Social Affairs, Population Division 2024: *World Population Prospects 2024: Summary of results* [jelentés]. [https://population.un.org/wpp/assets/Files/WPP2024\\_Summary-of-Results.pdf](https://population.un.org/wpp/assets/Files/WPP2024_Summary-of-Results.pdf) (letöltve 2025. 11. 14.)
- United Nations, Department of Economic and Social Affairs, Population Division 2005: *World Population Prospects: The 2004 Revision, Volume III: Analytical Report*. United Nations.
- Whelpton, P. K. 1928: Population of the United States, 1925 to 1975. *American Journal of Sociology*, 34. évfolyam, 2, 253–270.

## Melléklet

M1. ábra: Prompt-mátrix

	Strukturálatlan	Elnagyolt	Közepesen definiált	Strukturált
Feladat bemutatása	Általános feladatleírás			
	2023-as adatokat meg kell keresnie	2023-as adatokat Excelből kell kiolvasnia		
Feladat-specifikációk	Modellezési metódust kell találnia		Megadott modellezést kell követnie	
	Csak 3 forgatókönyv név adott	Ki vannak jelölve a vizsgálandó dimenziók (TTA, migráció)		
		Dimenziók értékei nem adottak	Dimenziók értékei kötöttek	
		További modellezési kérdések szabadok	Migráció, születések, halálozások is specifikáltak	
Eredmények bemutatása	Szabadabb forma	Kötött feladatok		
Magyarázat és indoklás	Mindenre kitérő	A hiányzó paraméterekhez		Nem szükséges
Egységes hibakezelés				
Egységes összehasonlítás a referenciaértékekkel				

**Forrás:** Századvég-szerkesztés