



A STEM SZAKOKON ÉS KURZUSOKON NYÚJTOTT EGYETEMI TELJESÍTMÉNYT ELŐRE JELZŐ KOGNITÍV TÉNYEZŐK FELTÁRÁSÁNAK MÓDSZEREI – NARRATÍV SZAKIRODALMI ÁTTEKINTÉS

D. Nagy Fruzsina¹, Korom Erzsébet^{2,3}

¹ Szegedi Tudományegyetem Neveléstudományi Doktori Iskola

² Szegedi Tudományegyetem Neveléstudományi Intézet

³ MTA-SZTE Digitális Tanulási Technológiák Kutatócsoport

Napjainkban az egyetemi hallgatók teljesítményét előre jelző kutatások, modellek fő mozgatórugói a lemorzsolódás okainak feltárása és annak csökkentése mind a nemzetközi, mind a hazai környezetben. Az OECD 2020-as adatai alapján a BSc képzést elkezdő hallgatók 39%-a kap diplomát az elméleti képzési időn belül, ami plusz 3 év távlatában 68%-ra növekszik (OECD, 2022). A hallgatók 12%-a már a második egyetemi tanéve előtt megszakítja tanulmányait, és ezen arány az elméleti képzési idő 3 éves távlatában 23%-ra nő. (Ezek az elemzésekben részt vevő OECD-országokra vonatkozó, átlagos adatok. Az adatokat szolgáltató országok között nem szerepel Magyarország, így a hazai mutatók nem ismertek.)

A felsőoktatási tanulmányok elemzését a STEM (*Science, Technology, Engineering and Mathematics*) szakokra szűkítve elmondható, hogy kifejezetten nagy a természettudomány, az informatika és a mérnöki diplomával rendelkezők iránti munkaerőpiaci igény, azonban a 2021-es OECD-adatok alapján a felsőoktatásban tanulók – alap-, mesterszakos és doktori hallgatók – 23%-a végez STEM szakon. Magyarországon ez az arány szintén 23%, míg Németországban a legmagasabb, de ott is csupán 35% (OECD, 2023). A STEM alapszakokat megkezdő hallgatók 68%-a szerez diplomát bármilyen szakon az elméleti képzési idő 3 éves távlatában, és csak 56%-a végez STEM tudományterületeken (OECD, 2023).

Ezen szakirodalmi tanulmány témája ezért kifejezetten aktuális és kulcsfontosságú, hiszen célja feltárni azokat a jellemzőket, amelyek hozzájárulhatnak a hallgatók felsőoktatási teljesítményének növeléséhez; ezáltal hozzásegítve őket a diploma megszerzéséhez. Az áttekintés egy jövőbeni empirikus kutatás alapját adja, melynek célja a kémia alapszakos hallgatók teljesítményében közrejátszó változók felderítése, segítségükkel pedig egy előre jelző modell megalkotása. A téma mélyebb feltárása érdekében azonban az előzetes kutatásokban részt vevő hallgatók szakját, illetve a vizsgált kurzusokat nem szűkítettük le kizárólag a kémia területére, hanem a tágabb területet tekintettünk át, vagyis a természettudományok, a technológia, a mérnöki tudományok és a matematika tudományterületeit egyaránt bevontuk az elemzésbe.

Fontos tisztázni az egyetemi teljesítményt mint gyakran használt fogalmat, mely egy számszerű érték, és a jelzésére általában egy kurzus érdemjegye vagy százalékos eredménye, a kumulatív átlag, vagy akár a diplomaszerezéskor számított tanulmányi átlag szolgál. Ezzel szemben az egyetemi sikeresség egy komplexebb fogalom, mely számos tényezőt (pl. szociális és

érzelmi jóllét, perzisztencia, elégedettség, készségek és kompetenciák elsajátítása) foglal magában, köztük az egyetemi teljesítményt.

Az egyetemi sikerességet és egyetemi teljesítményt vizsgáló átfogó tanulmányok, szisztematikus áttekintések különféle szempontok alapján kategorizálják a teljesítményben és sikerben szerepet játszó tényezőket (Alyahyan & Düşteğör, 2020; Kocsis & Molnár, 2024; van der Zanden et al., 2018). Az egyik legegyszerűbb csoportosítási mód ezen faktorok kognitív és nem-kognitív halmazba való besorolása, melyet kutatásunk is követ. A két halmaz közötti határvonalat nehéz meghúzni. Összességében olyan változókat tekintünk elemzésünk során kognitívnek, melyek a diákok előzetes tudását, készségeit, felkészültségét jellemzik, mely lehet például egy érdemjegy vagy egy adott tantárgy érettségi eredménye.

Hosszabb távú célunk mind a kognitív, mind a nem-kognitív változók szerepének összegzése. A jelenlegi áttekintés az egyetemi teljesítményt magyarázó és előre jelző kutatások terjedelmes szakirodalma miatt elsősorban a kognitív faktorokat helyezi a középpontba, azaz olyan független változók keresését, melyek valamilyen előzetes ismeretet, tudást vagy készséget reprezentálnak. Tanulmányunk a STEM területeket tárja fel, így az áttekintésben olyan szakok és kurzusok szerepelnek, melyek a matematika, a kémia, a biológia, a fizika, az informatika, valamint a mérnöki tanulmányok területéhez tartoznak.

Célok, kutatási kérdés

A tárgyalásra kerülő tanulmányok száma mutatja a téma szakirodalmának gazdagságát, ugyanakkor elmondható, hogy ezen irodalom szintetizálására, rendszerezésére még nem létezik sem hazai, sem nemzetközi példa. A létező narratív vagy szisztematikus szakirodalmi áttekintések kimeneti tényezőként az egyetemi sikerességet veszik figyelembe, melynek számos komponense van, vagy kifejezetten a STEM szakok helyett egy adott felsőoktatási intézmény bármely szakjait vizsgálják (pl. Alyahyan & Düşteğör, 2020; Di Martino et al., 2023; Kocsis & Molnár, 2024; van der Zanden et al., 2018).

Szakirodalmi feltárásunk célja tehát olyan kutatások keresése és bemutatása, melyek az egyetemi teljesítmény előre jelző és meghatározó változóit, valamint elemzési módszereit vizsgálják. Az áttekintést vezérlő kutatási kérdések a következők:

- 1) Milyen kognitív tényezőkkel magyarázzák a STEM szakos vagy STEM kurzusra járó hallgatók egyetemi teljesítményét az eddigi tanulmányok?
- 2) Az egyetemi teljesítményt magyarázó tényezők közül melyeknek van szignifikáns előre jelző szerepük?
- 3) Milyen adatelemzési módszereket alkalmaznak az előre jelző hatás kimutatására?

Módszerek

Keresési protokoll

A kutatási kérdés megválaszolásához olyan tanulmányokat kerestünk, amelyek felsőoktatásban, STEM szakokon vagy kurzusokon tanuló alapszakos hallgatók teljesítményét magyarázzák bemeneti változókkal. A nemzetközi szakirodalom feltárását a Scopus adatbázisában végeztük angol nyelvű, referált cikkek keresésével, melyek címe, absztraktja vagy kulcsszavai tartalmaztak:

- 1) egy STEM szakra vagy kurzusra utaló kifejezést (pl. chemistry),
- 2) egy felsőoktatást reprezentáló szót (pl. university vagy college),
- 3) az előrejelzés, prediktálás szó változatát (pl. predict vagy prediction), valamint
- 4) a teljesítményt tükröző kifejezést (pl. performance).

A kulcsszavas keresés mellett hálóba-módszert is alkalmaztunk, azaz más cikkek bibliográfiájában kerestünk releváns szakirodalmat, melynek különösen az azonos kutatócsoportban készült cikkek feltárásában volt szerepe.

A vizsgálat időintervallumának az elmúlt 30 évet választottuk, ugyanis a STEM betűszó (kezdetben SMET) a 90-es évek közepén jelent meg először az USA-ban (National Science Foundation, 1996).

Maga a téma és szakirodalma majdnem egy évszázadra tekint vissza. A kezdeti tanulmányokban a kutatások célja a teljesítményt előre jelző tényezők feltárása (pl. Coley, 1973; Cornog & Stoddard, 1925), a beérkező hallgatók megfelelő szintű kurzusra való besorolása (pl. Demko et al., 1985; MacPhail & Foster, 1939), valamint a lemorzsolódás okainak megvizsgálása (pl. Hovey & Krohn, 1958, 1963) volt. Keresésünkkel akár 100 évet is visszamehetnénk, de a releváns szakirodalom javarésze az elmúlt 30 évvel lefedhető. Ennél rövidebb vizsgált időintervallumot pedig a meglévő, szintetizáló áttekintések hiánya miatt nem érdemes választani.

A kulcsszavas keresés 3756 találatot adott, melyekből kizárásra kerültek azon tanulmányok, melyek nem alapszakos hallgatókat vizsgáltak, bármely szakos hallgatókat együttesen vizsgáltak, kétszorosított kísérletet mutattak be (azaz valamely intervenció, fejlesztés hatása volt a középpontban), illetve a hallgatók vizsgált szakja orvosi, fogorvosi, gyógyszerészeti, közgazdasági tudományterülethez tartozott. A beválogatáshoz a tanulmányoknak a STEM szakos vagy STEM kurzusokra járó hallgatók egyetemi teljesítménye és az azt magyarázó tényezők közötti kapcsolatot kellett feltárniuk, a magyarázó tényezők között pedig szerepelnie kellett legalább egy kognitív változónak. Kizárólag referált cikkeket válogattunk be, az egyéb dokumentumtípusokat (konferenciatickek, könyvek, könyvfejezetek stb.) mind kizártuk. A szelektálás után az áttekintésbe 52 tanulmány került bevonásra, melyeket a teljes szöveg és az esetenként elérhető kiegészítő információk (*supplementary information*) alapján elemeztünk.

A keresés, a szelektálás és az eredmények bemutatása és diszkussziója során mindvégig követtük a szisztematikus szakirodalmi áttekintés módszerére jellemző szigorúságot. Ugyanakkor az áttekintendő cikkek száma miatt a válogatásunk nem lehet maximálisan objektív és teljeskörű, ezért ezen tanulmány az alkalmazott módszert tekintve narratív áttekintésnek tekinthető.

Elemzési szempontok

A feltárás során beválogatott tanulmányokat az alábbi szempontok szerint vizsgáltuk, elemeztük:

- 1) Milyen környezetben zajlott az adott vizsgálat (helyszín, részt vevő hallgatók szakja, vizsgálat célja)?
- 2) Milyen független változókat vettek figyelembe? A kognitív változók mellett megjelennek-e más változók is? Mely faktoroknak van ezek közül szignifikáns szerepük a teljesítményben?
- 3) Milyen adattal reprezentálták a teljesítményt?
- 4) Milyen statisztikai módszert alkalmaztak a teljesítmény és az azt befolyásoló változók közötti összefüggések jellemzésére?

Eredmények

A vizsgálatok kontextusa (helyszín, vizsgált kurzus vagy szak, a vizsgálat célja)

A vizsgálatok jelentős hányadát (36 tanulmány) az USA-ban végezték. Ebben közrejátsszik az is, hogy keresésünk során hólabda-módszert alkalmaztunk a korai szakirodalom felkutatásához, így a legkorábbi nem amerikai cikk, melyet elemzésünkbe bevontunk, 2010-ből származik. Az Egyesült Államok mellett végeztek kutatást a témában Ausztráliában (2 tanulmány), Belgiumban (2 tanulmány), Angliában (2 tanulmány), Németországban (2 tanulmány), Spanyolországban (2 tanulmány), a Dél-afrikai Köztársaságban (1 tanulmány), Hollandiában (1 tanulmány), Kubában (1 tanulmány), Izraelben (1 tanulmány), Nigériában (1 tanulmány) és Olaszországban (1 tanulmány) is.

A kutatások kontextusát befolyásolja a kultúra és az oktatási rendszer, amelyben születtek. A fent felsorolt országokban eltérő mind a középiskolai tanulmányokat lezáró érettségi (ha van), mind pedig a felsőoktatási felvételi rendszer.

Az amerikai felsőoktatási felvételi eljárásban minden leendő hallgatónak meg kell írnia egy sztenderdizált tesztet, ezeket belépő vizsgáknak is nevezik. A cikkekben előforduló, napjainkban is alkalmazott tesztek az SAT (*College Board Scholastic Aptitude Test*) és az ACT (*American College Testing*). Az SAT két részből (matematika, illetve szövegértés és -alkotás), az ACT pedig öt részből (matematika, szövegértés, angol mint anyanyelv, természettudományok, valamint egy opcionális szövegalkotás) részből áll. A cikkek többször hivatkoznak az ACT *Verbal* részpontszámára, ez a matematika kivételével mindent magában foglal. A jegyek tekintetében általában 13-fokú skálán osztályoznak (A+, A, A−, B+, B, B−, C+, C, C−, D+, D, D− és F), melyet gyakran százalékos formában kezelnek, vagy a betűvel kifejezett jegyeket egy 0 és 4 közötti skálára vetítik. Egy kurzus sikertelen teljesítését szinte minden cikk azonosan, a D vagy F jegyek megszerzésével, vagy a kurzus megszakításával (*W, withdrawal*) definiálja, ami százalékosan a 70% alatti teljesítményt jelenti. A beválogatott tanulmányokban többször megjelennek az USA-ban elterjedt *Advanced Placement (AP)* kurzusok, amelyeket a diákok középiskolában teljesíthetnek, és az adott tudományterület egyetemi szintű tananyagába adnak betekintést.

Belgiumban a sikeres középiskolai tanulmányokat igazoló bizonyítvány automatikus hozzáférést jelent a felsőoktatáshoz, így rendkívül heterogén csoportok kerülnek be a felsőoktatásba (Pinxten et al., 2019). Nincsen felvételi vizsga, illetve maga a középiskolai bizonyítvány sem kötődik a megszerzett tudás ellenőrzéséhez, ugyanis nincsenek érettségi vizsgák.

Angliában 16 éves korban szerezhető meg a GCSE (*General Certificate of Secondary Education*), ami nagyjából a magyar középszintű érettségi vizsgáknak felel meg, értékelése 1-től 9 fokig terjedő skálán történik. Ezután két év alatt szerezhető meg opcionálisan az A-level (*Advanced Level Qualification*) bizonyítvány; ekkor már a diákok választott, emelt szintű kurzusokra járnak. A felsőoktatásba való jelentkezéshez az intézmények előfeltételként írhatják elő bizonyos tantárgyakból az A-level képesítés meglétét. Az értékelés ebben az esetben hatfokú skálán történik (A*, A, B, C, D, E).

Németországban az érdemjegyek öt- vagy hatfokú skálán helyezkednek el, ahol az 1-es a legjobb jegy és a 4-es jegytől számít sikeresnek a teljesítés (az 5-ös vagy a 6-os érdemjegy bukást jelent). Találunk olyan kutatást, ahol változóként a középiskolai átlagot használják, ami a felvételt nyertek esetén legfeljebb 4-es; illetve olyat is, amelyben a skálát invertálják (Binder et al., 2019). Más esetben viszont az eredeti skálával dolgoznak (az 1-es továbbra is a legjobb), így a középiskolai átlag mint bemeneti tényező negatív előjelű hatása azt jelenti, hogy a jobb átlag esetén magasabb a kimeneti változó értéke is (Nolte et al., 2024).

A spanyol oktatási rendszerben az érdemjegyek 0-tól 10-ig terjedő skálán helyezkednek el, a sikeres teljesítéshez minimum 5,0 értékű átlagra van szükség. A felsőoktatási felvételi eljárásba jelentkezőknek kötelező felvételi vizsgát (*Selectividad*) kell tenniük, mely egy mindenkinek közös részből (négy vizsga) és egy speciális részből (2–4 választható vizsga) áll. A felvételi vizsga értékelése egy 0–14-es skálán történik. A közös rész vizsgáinak átlagából legfeljebb 10 pont szerezhető, és további 4 pont a választott vizsgák eredménye alapján, ezek súlyozásáról a felvételi intézmény dönt.

Hollandiában a középiskolát lezáró bizonyítványba minimum kilenc tantárgy eredménye kerül, melyet az adott tantárgy érettségi eredménye és a hozzá tartozó középiskolai kurzusok átlaga határoz meg.

A kubai felsőoktatási felvételi eljárásba való belépéshez a középiskolai tanulmányok sikeres teljesítését igazoló bizonyítványra (*Bachillerato*), illetve három felvételi vizsga (matematika, spanyol és történelem) teljesítésére van szükség. A megszerezhető jegyek 5, 4, 3 és 2, ahol a 2-es érdemjegy már a sikertelen teljesítést jelzi.

Izraelben a középiskolai tantárgyak szintjét ötfokú pontskálára sorolják be, a legtöbb tantárgy három, négy vagy öt pontot ér. A matematika esetén például a hárompontos szint a középszintet, a négypontos az emelt szintet, az ötpontos pedig az egyetemi szintű matematika-órákat jelenti. A középfokú tanulmányokat az érettségi vizsga (*Bagruyot*) zárja le, minden tantárgyhoz tartozó részvizsga esetén minimum 55%-os teljesítmény szükséges a sikeres teljesítéshez, a részvizsgák szintjét a tantárgy szintje (pontszáma) határozza meg.

Nigériában a tanulóknak kilenc évig kötelező a formális oktatásban részt venniük, ezután folytathatják tanulmányaikat további három évig, melyet a 7–9 tantárgyból álló érettségi vizsga zár le. A felsőoktatásba való jelentkezéshez felvételi tesztet kell írniuk. Az egyetemi kurzusok értékelése ötfokú skálán történik, a teljesítés minimum 45% esetén tekinthető sikeresnek.

Olaszországban a diákok 13 év formális oktatás után tesznek érettségi vizsgát, melynek eredménye képezi az alapját a felvételi eljárásnak. Az egyetemi kurzusok értékelése egy 30-pontos skálán történik, ahol minimum 18 pont szükséges a sikeres teljesítéshez.

A beválogatott tanulmányok kutatásaiban vizsgált kurzusok döntő része kémiakurzus (25 tanulmány), emellett vizsgáltak fizika-, biológia-, matematika- és programozókurzust is (4, 3, 3, illetve 1 tanulmány). Az egy szemeszternél hosszabb időszakot felölelő kutatásokban a hallgatók szakja is ismert, itt találkozunk kémia-, fizika-, biológiaszakkal, interdiszciplináris természettudományos szakkal (mely az előbbi tudományterületeket kombinálja, pl. King & Hambrook, 2021), mérnöki szakokkal (melyek számos szakot foglalhatnak magukban), illetve némely vizsgát az összetettségéből adódóan egyszerűen STEM szakként hivatkozik a vizsgált tanulók csoportjára.

Az elemzett vizsgálatok célkitűzése is sokrétű. Az egyik legáltalánosabb cél a lemorzsolódás csökkentése érdekében a teljesítményt meghatározó tényezők felderítése (pl. Binder et al., 2019); különösen igaz ez olyan, elsőszemeszteres kurzusokra, melyek alapfeltételét képezik a hallgató további tanulmányainak, és amelyeken a bukási arány kifejezetten magas (ezeket *gatekeeper* kurzusoknak hívják, pl. Williamson et al., 2020). Más esetekben a cél a felvételi követelmények megfelelőségének ellenőrzése (King & Hambrook, 2021), vagy az adott szak tantervének felülvizsgálata, ami olyan interdiszciplináris szakokon lehet fontos, mint például a mérnöki tudományok (pl. Whitcomb et al., 2020). Olyan kutatásra is találunk példát, melynek célkitűzése a nemek közötti különbségek feltárása volt oly módon, hogy a nem mint be nemeti változó szerepel az előre jelző modellben (Vincent-Ruz et al., 2018).

Az egyetemi teljesítményt meghatározó, előre jelző kognitív változók

A beválogatott tanulmányokban előforduló, az egyetemi teljesítményt befolyásoló faktorokat az adatok keletkezési ideje alapján három nagy csoportba soroltuk.

Az első csoportot alkotják a középiskolai tanulmányokat jellemző változók: a középiskolai érdemjegyek, a középiskolai tanulmányi átlag, az adott tantárgy középiskolában tanult szintje, az adott tantárgy tanulásával töltött évek száma a középiskolában, illetve a középfokú tanulmányokat lezáró vizsga (röviden: érettségi) eredménye.

A teljesítményt meghatározó faktorok második csoportját a középiskolai és egyetemi tanulmányokat átívelő időszak változói adják. Két faktort soroltunk ezen halmazba, az egyik a felvételi vizsga (rész)eredménye, a másik a felvételi pontszám. A felvételi vizsgát tekintve kiemelt szerepet kapnak az amerikai felsőoktatási felvételi eljárásban alkalmazott sztenderdizált tesztek, az SAT és az ACT, amelyek össz- vagy részpontszámát veszik figyelembe. Az SAT és az ACT más skálán mér, de eredményeik egymás között átjárhatók a pontszámok megfelelő átszámolásával, így összevont eredményt is lehet képezni (Stitzel & Raje, 2022). A másik tényező az adott intézmény felvételi eljárásában használt felvételi pontszám, vagy a hallgatók egyfajta rangsorolására alkalmazott intézményi mérőszám. Felvételi pontszámot kalkulálhatnak a középiskolai érdemjegyekből és az érettségi vagy felvételi vizsga eredményeiből (Gambini et al., 2024; Ortiz-Lozano et al., 2020), míg az intézményi mérőszámban a felvételi tesztek pontszáma, a középiskolai jegyek, az érettségi eredménye, a szak, illetve akár a középiskolai osztálybeli rangsorhelyezés (*class rank*) jelennek meg (Nakakoji & Wilson, 2018; Nurudeen et al., 2023; Vyas et al., 2021; Wagner et al., 2002).

A harmadik kategóriába tartoznak a hallgatók egyetemi tanulmányai során felvett adatok. Ezek a vizsgált időszak (általában a szemeszter) kezdetén felmért előzetes tudás és készségek, a korábbi kurzusok érdemjegye és átlaga, a teljesített kurzusok aránya, valamint a vizsgált kurzuson a félév közben szerzett érdemjegy. Az egyetemi teljesítményt meghatározó faktorokat és a példákat az 1. táblázat mutatja.

1. táblázat. Az egyetemi teljesítményt meghatározó faktorok a vizsgált kutatásokban

Változó	Részletek, megjegyzések	Tanulmányok
Középiskolai érdemjegyek	kémia, biológia, fizika, matematika, természettudományos tárgyak	King & Hambrook, 2021; Tai et al., 2005
Középiskolai tanulmányi átlag	minden tantárgy, vagy csak matematika / természettudományos tárgyak	Cooper & Pearson, 2012; Jones et al., 2010
Adott tantárgy középiskolában tanult szintje (heti matematikaórák száma alapján vagy akár bináris formában: járt egy adott szintű kurzusra vagy sem)	matematika, fizika, kémia, biológia	Hazari et al., 2007; Pinxten et al., 2019; Willems et al., 2019
Adott tantárgy tanulásával töltött évek száma a középiskolában	matematika, fizika, kémia, biológia	Sadler & Tai, 2001, 2007
Érettségi eredmények	—	Adkins & Noyes, 2018; De Winter & Dodou, 2011

1. táblázat folytatása

<i>Változó</i>	<i>Részletek, megjegyzések</i>	<i>Tanulmányok</i>
Felvételi vizsga eredménye	összpontszám vagy részpontszám (matematika, szövegértés, anyanyelvi és természettudományos rész, vagy az ACT <i>Verbal</i> része)	Vincent-Ruz et al., 2018; Vyas et al., 2021
Felvételi pontszám, intézményi mérőszám	középiskolai jegyek, érettségi/felvételi eredménye, szak, középiskolai osztálybeli rangsorhelyezés adataiból kalkulálva	Nurudeen et al., 2023; Vyas et al., 2021
A vizsgált időszak, általában a szemeszter kezdetén felmért előzetes tudás, készség	kvantitatív írni-olvasni tudás, térbeli tájékozódási képesség, természettudományos gondolkodás, logikus gondolkodás, előzetes ismeretek	Hieb et al., 2015; Leopold & Edgar, 2008
Korábbi kurzus(ok) érdemjegye, sikeres/sikertelen teljesítése, illetve, hogy járt-e egy adott kurzusra	matematika-, kémia-, fizikakurzusok jegye	Nakakoji & Wilson, 2018; Whitcomb et al., 2020
Korábbi kurzus(ok) átlaga	kumulatív átlag, kumulatív STEM / természettudományos / biológia átlag, az elsőéves kurzusok átlaga	Huang & Fang, 2013; Jones et al., 2010
A teljesített kurzusok aránya	teljesített kurzusok és összes kötelező kurzus számának hányadosa, megszerzett kreditmennyiség és összes felvett kredit hányadosa	Alvarez et al., 2020; Willems et al., 2019
A vizsgált kurzuson a félév közben szerzett jegy	zárthelyi dolgozat(ok) eredménye, kurzusok sikeres/sikertelen teljesítése	K. S. Lee et al., 2023; Ortiz-Lozano et al., 2020

Az előzetes ismeretek, készségek felmérésére számos vizsgálat saját fejlesztésű mérőeszközt alkalmazott. Ezen mérőeszközöket a 2. táblázat foglalja össze. Egy teszt kivételével minden esetben szerepet kap a matematikai készségek vizsgálata is, ami lehet számolási készség, az algebra témaköreinek ismerete, ábrázolás, arányossági gondolkodás vagy inkább elméleti jellegű kérdések megválaszolása (pl. Leopold & Edgar, 2008). Egyéb matematikai készségek vizsgálatára is van példa, ezek a kvantitatív írni-olvasni tudás (Shelton et al., 2021), a térbeli tájékozódási képesség (Nolte et al., 2024), illetve a logikus gondolkodás (Lewis & Lewis, 2007).

Találunk példát olyan tesztekre is, melyeket egy adott egyetem kurzusának oktatói fejlesztettek a saját hallgatóik mérésére. Mivel ezeket a feladatsorokat nem vetették alá statisztikai elemzésnek, a validitásukról és reliabilitásukról nem állnak rendelkezésre adatok, ezért ezen – az elemzésbe egyébként beválogatott – tanulmányok (Vyas et al., 2021; Willems et al., 2019; Xu et al., 2013) nem kerülnek említésre a 2. táblázatban.

Ahogy arra a bevezetésben is kitértünk, habár a kognitív és nem-kognitív halmazokba sorolás egy egyszerű csoportosítást adja a változóknak, azonban a kognitív változók köre erősen függ ezen halmaz definiálásától. Áttekintésünkben minden olyan változót ezen csoportba soroltunk, melyek a tanulók előzetes tudását, készségeit, teljesítményét közvetlenül (pl. érdemjegyek, előzetes teszt eredménye), vagy közvetetten (pl. tantárgy szintje, teljesített kreditek aránya) jellemzik.

2. táblázat. Mérőeszközök és az általuk vizsgált témák az elemzésbe bevont kutatásokban

<i>Mérőeszköz neve</i>	<i>Vizsgált tudományterület</i>	<i>Megjegyzés</i>	<i>Tanulmányok</i>
California Chemistry Diagnostic Test (CCDT)	matematika, kémia	matematikai szöveges feladat, általános kémiai ismeretek	Russell, 1994
Kaliforniai Állami Egyetem, Fullerton mérőeszköze	matematika, kémia	matematikai készségek, arányossági gondolkodás, ábraértelmezés, kémiai képletek, reakcióegyenletek	McFate & Olmsted, 1999
Student Pre-semester Assessment (SPSA)	matematika, kémia	algebra, mértékegység-átváltás, kémiai alapismeretek	Wagner et al., 2002
University of Minnesota Mathematics Assessment for Second-semester Chemistry (UnMMASSC)	matematika	matematikai jártasság: logaritmus, normálalak használata, ábrázolás és algebra	Leopold & Edgar, 2008
Diagnosztikai célú teszt	kémia (matematika)	előzetes tudás (pl. anyagmennyiség, oldatok, reakciók, számolási feladatok)	Potgieter et al., 2008
Diagnostic Algebra Test (DAT)	matematika (kémia)	algebra, kémia szöveges számolási feladatok	Cooper & Pearson, 2012
Algebra Readiness Exam (ARE)	matematika	algebra	Chariker et al., 2013
Math-Up Skills Test (MUST)	matematika (kémia)	számolási készségek (reakcióegyenlet rendezése)	Albaladejo et al., 2018
Előzetes tantárgyi tudás mérése	biológia, fizika	előzetes tárgyi tudás	Binder et al., 2019

Az egyetemi teljesítmény jelzőszáma

A kutatások előrejelezni vagy megmagyarázni kívánt változói szorosan kapcsolódnak a vizsgálatok időintervallumához, így a jobb áttekinthetőség érdekében a tanulmányokat ezen szempont szerint kategorizáltuk. Négy kategóriát határoztunk meg: (1) az egy félévet, (2) a két félévet, (3) a két tanévet és (4) a teljes képzési időt vizsgáló tanulmányokat (3. táblázat).

Az egyetlen félévet vizsgáló kutatásokban a kimeneti adat a vizsgált kurzuson szerzett érdemjegy, a kurzust lezáró vizsga vagy teszt eredménye, a kurzus sikeres/sikertelen teljesítése, a kurzuson szerzett első érdemjegy vagy a teljesített kreditmennyiség aránya az adott félévben. Az elemzésünkbe bevont, két félévet felölelő hat kutatásban a vizsgált két félév bizonyos kurzusainak érdemjegyét, vagy a kurzusok sikeres/sikertelen teljesítését, tanulmányi átlagát, illetve a teljesített kreditek arányát vettük figyelembe. Egy példát találtunk olyan kutatásra, ami két tanéven keresztül zajlott. Az említett kutatás során egy első féléves kurzus érdemjegyét, valamint az első két tanévben számított tanulmányi átlagot és a megszerzett kreditek számát

alkalmazták kimeneti változóként (Gambini et al., 2024). Összesen hat kutatás követte a hallgatókat a diploma megszerzéséig. Ezek a diplomaátlagot, a diploma megszerzésének tényét, valamint a korábbi kurzusok érdemjegyének átlagát használták függő változóként. Egyetlen kutatást találtunk, ami a diploma megszerzésével kapcsolatosan három kimeneti változót használt: a diák szerzett-e diplomát azon a szakon, amelyen tanulmányait megkezdte (nevezetesen biológia szakon), szerzett-e diplomát bármilyen szakon, valamint legalább 3,0 volt-e a diplomaátlaga (ami ebben az esetben bináris változó a diplomaátlag mint intervallumváltozóhoz képest) (Jones et al., 2010). Az egyszerűség kedvéért az első kettő változót a diploma megszerzésének ténye kategóriába, az utóbbit pedig a diplomaátlag kategóriába soroltuk.

3. táblázat. Az egyetemi teljesítmény mérőszámai a vizsgálat hosszának függvényében

Vizsgálat hossza	Kurzus érdemjegye	Kurzus sikeres teljesítése	Záróvizsga /teszt pontszáma	Tanulmányi átlag	Teljesített kredit száma / aránya	Diploma- átlag	Diploma megszer- zése	Tanulmányok
1 félév	✓							Loehr et al., 2012
		✓						Thompson et al., 2018
			✓					Nolte et al., 2024; Xu et al., 2013
					✓			Willems et al., 2019
	✓	✓						Powell et al., 2020; Williamson et al., 2020
	✓		✓					Vyas et al., 2021
2 félév	✓ több kurzus							Spencer, 1996; Whitcomb et al., 2020
		✓						Binder et al., 2019; Shelton et al., 2021
				✓ 1. és 2. szemeszter	✓			Pinxten et al., 2019
2 tanév	✓ 1. szemeszter			✓ 1. és 2. tanév	✓			Gambini et al., 2024
Bemenet- től a diplomáig						✓		Kohen & Nitzan, 2022; Nurudeen et al., 2023
							✓	Adkins & Noyes, 2018
						✓	✓	Jones et al., 2010
				✓ 2. szemeszter		✓		Nguyen et al., 2017
				✓ 1. és 2. szemeszter			✓	De Winter & Dodou, 2011

Az alkalmazott statisztikai módszerek

A kutatásokban felhasznált adatok az adatgyűjtés intervalluma és módja szerint is különböznek. Az adatgyűjtés hossza alapján találunk példát longitudinális és keresztmetszeti vizsgálatra egyaránt. A keresztmetszeti kutatások közé soroltuk azon eseteket is, amikor ugyanazon kurzus vizsgálatához több éven keresztül gyűjtötték az adatokat, majd együttesen kezelték azokat az elemzés során (pl. Y.-K. Lee et al., 2022; Legg et al., 2001; Lewis & Lewis, 2007).

Egyes kutatások retrospektív módon, azaz meglévő adatokból dolgoztak, ez kifejezetten jellemző a longitudinális kutatásokra, amelyek a diplomáig követték a hallgatókat (l. Adkins & Noyes, 2018; De Winter & Dodou, 2011; Jones et al., 2010; Kohen & Nitzan, 2022; Nguyen et al., 2017; Nurudeen et al., 2023). Más tanulmányok prospektív adatfelvételt alkalmaztak, tehát új adatokat gyűjtöttek a vizsgálati periódusban, ez különösen igaz a saját fejlesztésű mérőeszközt, tesztet alkalmazó kutatások (Binder et al., 2019; Cooper & Pearson, 2012; Wagner et al., 2002) esetében.

Leíró statisztikai módszereket minden kutatás alkalmazott a minta jellemzésére, bemutatására és az eredmények közlésére. Találunk példát olyan kutatásra, mely ennél összetettebb elemzéseket nem is végzett, például Spencer (1996) derékszögű koordináta-rendszerben megjelenített adatpontokról vont le következtetéseket.

Az összetettebb, de még mindig leíró statisztikát használó kutatások korrelációs számításokat végeztek az egyetemi teljesítmény és az azt feltételezeten befolyásoló változók között, erre négy példa adódik (Donovan & Wheland, 2009; Kolopajlo, 2019; Leopold & Edgar, 2008; McFate & Olmsted, 1999). Mivel a korrelációs együttható ok-okozati kapcsolatot nem ad meg a változók között – előjele a kapcsolat irányát, abszolútértéke annak erősségét mutatja –, ezzel az elemzéssel nem lehet az egyik változó értékéből a másikat előre jelezni.

A bináris kimeneti változót (egy kurzus sikeres vagy sikertelen teljesítése) elemző kutatások általában logisztikus regressziós modellt, az érdemjegyet vagy pontszámot prediktáló kutatások javarészt lineáris regressziós modellt alkalmaztak. A regresszióanalízis lehetőséget ad arra, amire a korrelációs számítás nem: a bemeneti változó(k) segítségével prediktálja a függő változót. Az egyes független változókhoz tartozó regressziós együttható előjele és nagysága megadja az adott faktor hatását az egyetemi teljesítményre.

A regresszióanalízis során elméletileg olyan független változók kerülhetnek be a modellbe, melyek nem korrelálnak erősen egymással, ezért ezt korrelációs számítással kell ellenőrizni. A legtöbb kutatás, amely regressziós modellt használt, eleget tett ezen feltételnek (l. De Winter & Dodou, 2011; Gambini et al., 2024; Kim et al., 2022; Kreiser et al., 2022; Lewis & Lewis, 2007; Pinxten et al., 2019; Russell, 1994; Sadler & Tai, 2001; Thompson et al., 2018), de ennek ellenkezőjére is van példa (l. Stitzel & Raje, 2022; Willis et al., 2022). Több kutatás lineáris és logisztikus regressziós modellt is felállított (l. pl. K. S. Lee et al., 2023; Velázquez et al., 2023).

Két vizsgálat alkalmazott varianciaanalízist (ANOVA) (King & Hambrook, 2021; Shelton et al., 2021), ami a tanulócsoportok közötti különbségek megállapítására adott lehetőséget. Hat kutatásban alkottak modellt a strukturális egyenletek módszerével (*SEM*), (pl. Graafsma et al., 2023; Willems et al., 2019), melynek előnye, hogy a független változók közötti kapcsolatokat is segít feltárni.

Születtek az eddig tárgyaltaknál összetettebb, bonyolultabb vagy éppen a neveléstudományi elemzésekben kevésbé alkalmazott modellek is. Két esetben készült modell döntési fák (*decision tree*) megalkotásával, melyek matematikai értelemben gráfoknak tekinthetők (Alvarez et al., 2020; Ortiz-Lozano et al., 2020). A modell olyan kritériumokat határoz meg,

melyek mentén két irányban halad tovább, onnan megint két-két irányban elágazhat, és így tovább; tehát a modell grafikus megjelenése valóban egy fához hasonlít.

Három tanulmányban akad példa mesterséges neurális hálózatra, ami sematikusán úgy képzelhető el, mint az emberi agy neuronhálózata (Alvarez et al., 2020; Cooper & Pearson, 2012; Huang & Fang, 2013). A modell mögött nincsen explicit matematikai elképzelés a bemeneti és kimeneti változók kapcsolatára vonatkozóan, a modell attól lesz optimális, hogy a neuronok „tanulnak”, azaz a felmerülő hibák alapján javítják magát a modellt. A neurális hálózatok két típusa figyelhető meg a tanulmányokban, ezek a többrétegű előrecsatolt neurális hálózat (*multilayer feedforward neural network*) és a radiális bázisfüggvény hálózat (*radial basis function network*).

A neurális hálózatok mellett Huang és Fang (2013) készített két másik modellt is, ezek egyikét lineáris regresszió segítségével, a másikat pedig a tartóvektor-gép (*support vector machine*) segítségével. A tartóvektor-gép a hozzá hasonló neurális hálózatoktól abban tér el, hogy ebben az esetben nem a kísérletezés vagy a gépi tanulás, hanem a matematikai háttér kialakítása a fő szempont.

Fontos megjegyezni, hogy egy kutatás során jellemzően több modell is készül. Ezen modelleket legtöbbször megbízhatóan össze lehet hasonlítani, mert vagy ugyanolyan statisztikai módszerrel készülnek (pl. lépcsőzetesen vesznek be változókat a lineáris regressziós modellbe), vagy különböző módszer esetén ugyanazon mérőeszközökkel mérik ugyanazon bemeneti és kimeneti változókat (pl. ugyanazon változókkal készítenek egy lineáris regressziós és egy strukturális egyenletek modellezésén alapuló modellt). A végső modellt a kutatások különböző módon választják meg. Egyes esetekben a szignifikáns és nem szignifikáns változókat is benne hagyják a modellben, mert minél több a független változó, a kimeneti változó varianciáját annál nagyobb arányban magyarázza meg (pl. Hieb et al., 2015). Más modellekben kizárólag azon változók szerepelnek, melyek szignifikáns magyarázó erővel bírnak (pl. Tai et al., 2005). Néhány kutatás előzetesen választ kontrollváltozókat, melyek hatására nem kíváncsiak a kutatók, viszont a bevételük a modellbe alapvonalként szolgál, így a ténylegesen vizsgálni kívánt változók hatása jobban kimutatható (pl. Tai et al., 2006; Vincent-Ruz et al., 2018). Emellett lehet egy szempont a végső modell kiválasztására az is, hogy addig veszik be a változókat a modellbe, amíg azok a megmagyarázott variancia értékét szignifikánsan megnövelik (pl. Kim et al., 2022; Nolte et al., 2024).

A modellek illeszkedése, előrejelzési pontossága

A modellek illeszkedése a megmagyarázott variancia százalékos értékével adható meg. A tanulmányokban találunk kifejezetten jó illeszkedésű ($R^2=98,8\%$, Nurudeen et al., 2023), valamint rossz illeszkedésű ($R^2=13,5\%$, Nguyen et al., 2017) modelleket is. Ez a variancia-érték azért kiemelt fontosságú, mert a legtöbb kutatásban ez alapján választják a végső modellt. Szeretnénk azonban felhívni a figyelmet arra, hogy a megmagyarázott variancia értéke azt jelzi, hogy a modell milyen mértékben illeszkedik a meglévő adatpontokra. Vagyis a variancia értéke nem feltétlenül alkalmas olyan modell kiválasztására, amely előrejelzésre is megbízhatóan használható.

A „legjobb” modell definiálása és kiválasztása tehát összetett folyamat, melyet a beavogatott tanulmányok egy része figyelembe is vesz azáltal, hogy alkalmazza az előrejelzési pontosság (*prediction accuracy*) fogalmát. Ez a százalékos érték azt fejezi ki, hogy hány tanuló kapta valóban azt az érdemjegyet vagy sikeres/sikertelen besorolást, amelyet a modell előrejelzett számára. Két másik, speciálisabb fogalom is bevezetésre kerül: a specifitás azt fejezi

ki, hogy a modell által sikeres teljesítőnek jósoltak hány százaléka teljesítette valóban a vizsgált kurzust, míg a szenzitivitás azt mutatja meg, hogy a modell által sikertelen teljesítőnek jósoltak hány százaléka bukott meg valóban az adott kurzuson.

Ezen értékekhez a modell tesztelésével juthatunk. A tesztelés egyik lehetősége az adott periódusban gyűjtött adathalmaz random kettéosztása: az egyik részen felállítjuk a modellt, a másikon pedig kipróbáljuk (pl. Williamson et al., 2020). A másik lehetőség az, hogy több éven keresztül gyűjtünk adatokat egy adott kurzuson, és időszakok szerint felosztva az adatokat, elkészítjük, majd teszteljük a modellt (Huang & Fang, 2013).

A 4. táblázatban azon tanulmányokat gyűjtöttük össze, amelyek kiszámolták a felsorolt három adat (előrejelzési pontosság, specificitás, szenzitivitás) valamelyikét. Egyes tanulmányokhoz több sor tartozik, amik különböző modelleket jelölnek. Ezen különböző modellekhez úgy jutottak a kutatók, hogy további változókat vettek be az elemzésbe (Alvarez et al., 2020; K. S. Lee et al., 2023; Worthley et al., 2016) vagy több szakot vizsgáltak, és szakonként más-más modellt készítettek (Binder et al., 2019; Nguyen et al., 2017). Ahol ugyanazon adatokkal többféle statisztikai módszerrel készült modell, intervallumként adtuk meg a számadatokat (pl. Huang & Fang, 2013).

4. táblázat. A modellek előrejelzési pontosságát, specificitását vagy szenzitivitását kiszámoló tanulmányokban kapott adatok

<i>Előrejelzési pontosság (%)</i>	<i>Specificitás (%)</i>	<i>Szenzitivitás (%)</i>	<i>Megmagyarázott variancia (%)</i>	<i>Tanulmányok</i>
76,3	90,6	40,8	–	Wagner et al., 2002
76,0	46,0	92,0	–	Potgieter et al., 2010
83,0	–	76,0	–	Cooper & Pearson, 2012
61,3–64,0	–	–	–	Huang & Fang, 2013
77,3	89,7	38,7	–	Worthley et al., 2016
79,5	90,5	33,3	–	
64,1–67,2	–	–	22,2–22,3	Nguyen et al., 2017
79,2–79,7	–	–	13,5–15,0	
68,3	–	–	17,2	Binder et al., 2019
82,2	–	–	59,0	
66,67–68,86	–	–	–	Alvarez et al., 2020
93,85–96,71	–	–	–	
96,49–96,71	–	–	–	
78,0	–	–	–	Williamson et al., 2020
83,0	–	–	20,5 és 12,7	Powell et al., 2020
70,1	–	–	16,0–22,0	Stitzel & Raje, 2022
84,6	–	–	–	Willis et al., 2022
–	80,0	64,0	33,1	K. S. Lee et al., 2023
–	88,0	82,0	66,7	
–	97,0	82,0	77,8	
68,8	74,7	62,1	29,4	Velázquez et al., 2023

A 4. táblázat első három oszlopa alapján két konklúziót vonhatunk le. Egyrészt az előrejelzési pontosság minden esetben magas, 60% feletti, tehát ekkora biztossággal kapja egy hallgató valóban azt a jegyet, illetve a sikeres/sikertelen besorolást, amit a modell jósolt. Másrészt azoknál a modelleknél, ahol mind a specifikitás, mind a szenzitivitás adott, a szenzitivitás értéke alacsonyabb, azaz a sikertelen teljesítőket kisebb bizonyossággal tudják előre jelezni, pedig ezen modelleknek kifejezetten ez lenne a célja. Erre találunk egy ellenpéldát is a táblázatban, Potgieter et al. (2010) tanulmányát, viszont fontos kiemelni, hogy ők csak azon hallgatók adataival építették fel a modellt, akiknek C vagy annál rosszabb volt a 12. évfolyamon szerzett matematikajegyük; ezért lehet magasabb a szenzitivitás értéke. A többi tanulmány alapján ez nem ideális modellépítési technika, ugyanis az előzetesen jól teljesítők között is találunk sikertelen hallgatókat vagy a megjósoltnál gyengébben teljesítőket; ellenkező esetben a specifikitás értéke 100% lenne.

A megmagyarázott variancia értékét, ahol rendelkezésre állt, feltüntettük a 4. táblázatban. Ezen értékek alapján jogos az alfejezet bevezető kérdése, hogy mely tulajdonság definiálja a legjobb modellt, ugyanis a magas varianciaérték nem feltétele a magas előrejelzési pontosságnak. Láthatunk kifejezetten rossz illeszkedésű modelleket, melyek mégis nagy biztossággal kategorizálják helyesen a hallgatókat (Nguyen et al., 2017; Powell et al., 2020; Stitzel & Rajee, 2022).

Említésre méltók azok a tanulmányok is, melyek az előzőekben részletezett előrejelzési pontosságot nem a felállított modell, hanem egy adott mérőeszköz vagy mutatószám jellemzésére használják (Lewis & Lewis, 2007; McFate & Olmsted, 1999; Vyas et al., 2021; Wagner et al., 2002). Ez azt jelenti, hogy meghatároznak egy-egy küszöbértéket (erre gyakran *cut-off score*-ként hivatkoznak), mely pontszám vagy érték alatt lemorzsolódással veszélyeztetettnek, ezen értéken vagy felette pedig lemorzsolódással nem veszélyeztetettnek kategorizálják a hallgatókat. A mérőeszközök és mutatószámok előrejelzési pontossága azt jelzi, hogy ezen küszöbértéknél két részcsoportra bontva a hallgatókat, azok hány százaléka került valójában a megfelelő csoportba a teljesítménye alapján. A tanulmányokban megtalálható mérőeszközök és mutatószámok előrejelzési pontosságát az 5. táblázat foglalja össze. Ezen eszközök alkalmazása lehetővé teszi azon hallgatók egyszerű azonosítását, akik nagy valószínűséggel nem fogják tudni teljesíteni az adott kurzust.

Az elemzésbe bevont kutatásokban vizsgált nem-kognitív változók

Bár tanulmányunk elsődleges célja a kognitív változók vizsgálata, a következőkben röviden bemutatunk néhány, az elemzett kutatásokban gyakran megjelenő nem-kognitív változót. Ezek összegzése, áttekintése elősegítheti egy későbbi, a nem-kognitív változók szerepére irányuló szisztematikus szakirodalmi feltáró munka tervezését.

Az elemzett kutatásokban megjelenő nem-kognitív változók nagy csoportját képezik a demográfiai változók. Demográfiai adatokat szinte minden kutatás során gyűjtenek, azonban ezek nem minden esetben kerülnek bele az előrejelző modellekbe. A leggyakrabban felvett demográfiai változók a nem, az életkor, a rassz/etnicitás, a lakóhely, a szülők iskolai végzettsége, valamint a szak (ez utóbbi akkor jellemző, ha a kutatók több szakról vizsgálnak hallgatókat, de egyetlen közös modellt állítanak fel). Egyes esetekben ezen változókat kontrollváltozóként benne hagyják az előrejelző modellben akkor is, ha nincs szignifikáns hatásuk, mivel így megbízhatóbb a végleges modell (Sadler & Tai, 2007; Vincent-Ruz et al., 2018).

A vizsgált kutatások között vannak olyanok is, amelyekben a demográfiai jellemzők a teljesítmény szignifikáns jelzőiként jelennek meg. Ezen változók közül a leggyakrabban előfordulókat a 6. táblázat foglalja össze.

5. táblázat. A mérőeszközök és mutatószámok előrejelzési pontossága, specificitása és szenzitivitása

<i>Mérőeszköz, mutatószám</i>	<i>Küszöbérték</i>	<i>Előrejelzési pontosság (%)</i>	<i>Speci- ficitás (%)</i>	<i>Szenzi- tivitás (%)</i>	<i>Tanulmányok</i>
Kaliforniai Állami Egyetem, Fullerton mérőeszköze	50%	67,0	–	–	McFate & Olmsted, 1999
Toledo vizsga	51%	75,1	87,0	27,7	Wagner et al., 2002
SAT matematika részének pontszáma	440 (200–800 skálán)	75,0	91,3	23,1	
Student Pre-semester Assessment (SPSA)	45%	74,1	87,7	40,8	
Saját intézményi mérőszám	54%	69,9	84,0	29,4	
SAT összpontszáma	860 (400–1600 skálán)	69,2	89,6	16,8	
SAT szövegértés és –alkotás részének pontszáma	400 (200–800 skálán)	67,4	90,9	10,4	Lewis & Lewis, 2007
Test of Logical Thinking (TOLT)	40%	–	–	70,5	
SAT matematika, valamint szövegértés és -alkotás részének összpontszáma	500 (legalább az egyik rész pontszáma esetén, 200-800 skála)	–	–	72,5	
ACS diagnosztikus teszt	78,3%	42,0–45,0	–	–	Vyas et al., 2021
Adaptív matematika-kémia teszt	65%	39,0–42,0	–	–	
Saját intézményi mérőszám	70,75%	35,0–42,0	–	–	

6. táblázat. Az egyetemi teljesítmény szignifikáns előre jelzőjeként megjelenő leggyakoribb demográfiai változók

<i>Változó</i>	<i>Tanulmányok</i>
Nem	Hazari et al., 2007; Jones et al., 2010; Y.-K. Lee et al., 2022; Legg et al., 2001; Powell et al., 2020; Sadler & Tai, 2007; Willems et al., 2019; Williamson et al., 2020; Willis et al., 2022
Rassz / etnicitás	Adkins & Noyes, 2018; Cooper & Pearson, 2012; Hazari et al., 2007; Jones et al., 2010; Y.-K. Lee et al., 2022; Loehr et al., 2012; Powell et al., 2020; Sadler & Tai, 2001; Tai et al., 2005, 2006; Tai & Sadler, 2007; Williamson et al., 2020; Willis et al., 2022
A hallgató életkora	Wagner et al., 2002; Willems et al., 2019
A hallgató évfolyama	Powell et al., 2020; Sadler & Tai, 2001; Stitzel & Raje, 2022, 2022; Tai et al., 2005, 2006; Tai & Sadler, 2007; Williamson et al., 2020
A hallgató szakja	Powell et al., 2020; Stitzel & Raje, 2022; Williamson et al., 2020; Willis et al., 2022
A szülők és/vagy nagyszülők iskolázottsága	Y.-K. Lee et al., 2022; Loehr et al., 2012; Powell et al., 2020; Sadler & Tai, 2001; Tai et al., 2005, 2006; Tai & Sadler, 2007; Williamson et al., 2020; Willis et al., 2022
Egyetemi tanulmányok melletti munkaviszony, heti munkaórák száma	Powell et al., 2020; Stitzel & Raje, 2022; Williamson et al., 2020; Willis et al., 2022
A hallgató magániskolában végezte-e a középiskolai tanulmányait	Sadler & Tai, 2001
A hallgató középiskolája külvárosban található-e	Sadler & Tai, 2001
A hallgató ingázik-e az egyetemi kampuszra	Stitzel & Raje, 2022

Találunk további szignifikáns változókat a modellekben, amelyek nem sorolhatók be a demográfiai változók csoportjába, ezeket a 7. táblázat szemlélteti.

7. táblázat. A teljesítmény szignifikáns előre jelzőjeként megjelenő, nem-kognitív és nem demográfiai változók

Változó	Tanulmányok
Középiskolai matematika-, fizika-, kémia-, biológiaórák tapasztalatai (alkalmazott tanítási módszerek, tanmenet, heti tanórák száma, a hallgatók szerint a tanítás minősége)	Hazari et al., 2007; Loehr et al., 2012; Sadler & Tai, 2001; Tai et al., 2005, 2006; Tai & Sadler, 2007; Willems et al., 2019; Worthley et al., 2016
A hallgatók motivációja	Hieb et al., 2015; Pinxten et al., 2019; Worthley et al., 2016
A hallgatók által alkalmazott tanulási stratégiák	Pinxten et al., 2019; Willems et al., 2019; Worthley et al., 2016
A hallgatók attitűdje	Kim et al., 2022; Tai et al., 2005; Vincent-Ruz et al., 2018
Az önértékelési pontosság, mely egy teszten a diákok által megbecsült és valójában elért pontszám hányadosa	Potgieter et al., 2010
A professzor és a tanuló nemének megegyezése	Sadler & Tai, 2001

Diszkusszió, következtetések

Szakirodalmi kutatásunk célja azon kognitív változók felkutatása volt, melyek egy STEM szakra vagy STEM kurzusra járó hallgatók egyetemi teljesítményét szignifikánsan befolyásolják, előre jelzik. A feltárt kutatások mutatják, hogy a téma nemzetközi szakirodalma kifejezetten gazdag és számos nézőpontból megközelített.

A teljesítményt befolyásoló kognitív tényezők között találjuk a középiskolai tanulmányokat, a középiskola és az egyetemi tanulmányok közötti időszakot, valamint az egyetemi tanulmányok jellemzőit is. E három nagy faktor mentén tizenkettő változót különítettünk el, melyeket az 1. táblázatban foglaltunk össze. A prediktáló hatásukkal kapcsolatosan megállapítható, hogy közülük hét változó minden vizsgált esetben szignifikánsnak bizonyult. Ezek a változók a középiskolai érdemjegyek (matematika, kémia, biológia, természettudomány, angol mint anyanyelv); az adott tantárgy (matematika, fizika) tanulásával töltött évek száma a középiskolában; a felvételi pontszám és intézményi mérőszám; a korábbi kurzusok (matematika, kémia, fizika, informatika) érdemjegye, teljesítése; a korábbi kurzusok átlaga (kumulatív átlag, kumulatív természettudományos vagy STEM átlag); a teljesített kurzusok (pl. informatika) aránya, valamint a vizsgált kurzusokon (mérnöki kurzus, kémiakurzus) a félév közben szerzett jegy. Jól látszik, hogy az egyetemi tanulmányok időszakából származó adatok majdnem mindegyike szignifikáns előre jelzője az egyetemi teljesítménynek, így ezen változókat célszerű lehet bevonni az új kutatások longitudinális vizsgálataiba is. Érdemes viszont azt is figyelembe

venni, hogy mi az adatfelvétel célja, ugyanis ezen adatok meglétének időpontjában egy esetleges intervencióra, felzárkóztatásra már nem feltétlenül van lehetőség.

Az elemzett kutatásokból az is kiderült, hogy nem minden esetben szignifikáns a középiskolai tanulmányi átlag (mely minden tantárgy érdemjegyét magában foglalja); az adott tantárgy (kémia, biológia, fizika) középiskolában tanult szintje; az érettségi egyes tárgyainak (idegen nyelvek) eredménye; a felvételi vizsga össz- vagy részpontszáma (ACT *Verbal* vagy anyanyelvi része, matematika rész, összpontszám), illetve a szemeszter kezdetén felmért előzetes tudás, készség (algebra, térbeli tájékozódási képesség). Az esetek többségében ezek a változók is szignifikáns prediktorok, a felsorolt példák inkább kivételnek minősülnek, így érdemes lehet ezeket a változókat is mérni, illetve összegyűjteni, majd bevinni az előrejelző modellekbe. Ezen változók alkalmazása mellett szól az is, hogy vagy már rendelkezésre álló adatokról (középiskolai érdemjegyek, érettségi és felvételi vizsga eredménye) van szó, vagy felvételük könnyen kivitelezhető egy rövid idő alatt kitölthető és egyszerűen kiértékelhető teszttel az adott félév kezdetén.

A bevont változók jelentőségének vizsgálatakor figyelembe kell vennünk a tanulmányok kulturális kontextusát is, mely az ellentmondásos eredményeket háttérben állhat. Erre jó példa az adott tárgy középiskolában tanult szintjét reprezentáló változó, mely az amerikai kutatások mindegyikében szignifikáns, a belgiumi (Willems et al., 2019) és angliai (King & Hambrook, 2021) kutatásokban viszont nem.

Elemzésünk egyik fontos konklúziója, hogy míg a vizsgált STEM kurzushoz vagy szakhoz köthető előzetes tudás nem minden tanulmányban kap szerepet, addig a matematika minden egyes kutatásban, modellben megjelenik: a vizsgált változók tartalmazhatják a matematikai tudást közvetett (pl. középiskolai tanulmányi átlag, érettségi vizsga eredménye, kumulatív STEM átlag) vagy közvetlen (középiskolai matematika érdemjegy, a matematika tanulásának szintje a középiskolában, a felvételi vizsga matematika részének pontszáma, az előzetes matematikatudást mérő teszt pontszáma) formában. Mindez felhívja a figyelmet arra, hogy a nemzetközi szakirodalom alapján a STEM kurzusokon és szakokon egyre inkább használatos az integrált STEM megközelítés, melynek alapja a különböző STEM tudományterületekről származó tudás összekapcsolása (Nadelson & Seifert, 2017).

Habár áttekintésünk fő célja a kognitív változók prediktáló hatásának feltárása volt, számos tanulmányban a nem-kognitív változók is szerepet kaptak. A beválogatott cikkek modelljeiben megtalálható nem-kognitív változók többsége inkonzisztens szerepű, vagyis némely kutatásban szignifikáns, némely kutatásban pedig nem szignifikáns szerepet tölt be; ilyen változók a rassz/etnicitás, a nem, a hallgató évfolyama, az életkor, valamint a munkavállalás. Egyetlen változót érdemes kiemelni, mely minden vizsgált esetben szignifikánsnak bizonyult, ez a szülők és/vagy nagyszülők legmagasabb iskolai végzettsége, melyet a tanulmányok leggyakrabban abba a változóba sűrítettek be, hogy a hallgató hányadik generációs egyetemista.

A megvizsgált tanulmányok döntő többségéről elmondható, hogy ha kognitív és nem-kognitív változókat egyaránt vizsgáltak, a kognitív változók hatása jelentősebb volt az egyetemi teljesítmény előrejelzésében. Ugyanakkor néhány ellenpéldát is találtunk: egyes esetekben olyan nem-kognitív változó a legerősebb prediktor, mint a rassz (Y.-K. Lee et al., 2022), az évfolyam (Stitzel & Raje, 2022), vagy az önértékelési pontosság (Potgieter et al., 2010). Sadler és Tai (2001) azon modelljében, melyben a középiskolai fizikaórák tapasztalatai is szerepeltek, a „vizsgált fizikakurzust tartó professzor és a tanuló neme megegyezik” változónak volt a legnagyobb hatása. Egyes tanulmányokban a kognitív és nem-kognitív változók viszonyáról nem mondhatunk biztosat, melynek oka lehet a modell jellege (Powell et al., 2020; Willis et al., 2022), a sztenderdizált regressziós együtthatók hiánya (Hazari et al., 2007; Loehr et al., 2012), vagy bizonyos változók kontrollként való alkalmazása, melyek hatása így nem ismert (Kim et

al., 2022; Sadler & Tai, 2007). A nem egyértelmű eredmények felvetik a kérdést, hogy ezen változókat érdemes-e vizsgálni. Mellettük szól, hogy kérdőíves módszerrel adatfelvételük gyors, valamint, hogy több esetben a nem-kognitív változók adták a modellek legerősebb prediktorát (Y.-K. Lee et al., 2022; Potgieter et al., 2010; Stitzel & Raje, 2022). Természetesen, mivel a szakirodalmi áttekintésünkben a tanulmányok válogatása során a kognitív változók jelenléte volt a feltétel, teljeskörű képet a nem-kognitív változók szerepéről egy újabb, szélesebb körű szakirodalmi feltárás során kaphatnánk.

Szakirodalmi áttekintésünk eredményei, következtetései közvetlenül alkalmazhatóak empirikus kutatásokban. Rámutatnak arra, hogy egy STEM szakon vagy kurzuson való teljesítményt előre jelző tényezők vizsgálatakor több szempontra is érdemes odafigyelni. Ilyen például, hogy pontosan gondoljuk át, határozzuk meg a vizsgálat célját. Ha a kutatás hosszú távú célkitűzése az esetlegesen lemaradó hallgatók prospektív azonosítása és felzárkóztatása, az azonosításukat minél hamarabb érdemes megtenni. Ennek érdekében az adatgyűjtést a vizsgált időszak kezdetén kell lebonyolítani, hogy maradjon idő egy lehetséges intervencióra. Keresztmetszeti adatfelvétel esetén a vizsgálandó kognitív változók közé célszerű bevenni a középiskolai érdemjegyeket, a középiskolai tantárgyak tanulmányának szintjét, az érettségi vagy felvételi vizsga eredményét, illetve a félév eleji diagnosztikus teszt(ek) eredményét, míg longitudinális kutatás esetén ezen adatokhoz érdemes hozzávenni a hallgatók egyetemi teljesítményét (kurzusok érdemjegye, kumulatív átlag) is. A tantárgyak, tudományterületek tekintetében a matematikát, valamint a vizsgált szakhoz közeli természettudományos tárgyakat célszerű előtérbe helyezni (pl. az utolsó középiskolai tanév matematika érdemjegye, a fizika tanulmányának szintje középiskolában). Az előre jelző modell készítése során törekedjünk a korrelációnál összetettebb módszerek (minimum regresszióanalízis) használatára, arra figyelve, hogy nem feltétlenül a varianciát legmagasabb mértékben megmagyarázó modell a legjobb; valamint ne csak felállítsuk, hanem teszteljük is a modellt, számoljunk előrejelzési pontosságot, szenzitivitást, specifitást.

Összegzés, további kutatások

Szakirodalmi áttekintésünkben azokat a kutatásokat tekintettük át, amelyek a STEM szakos vagy STEM kurzusra járó hallgatók egyetemi teljesítményét előre jelző kognitív változókat vizsgálták az elmúlt harminc évben. Az elemzésbe bevont tanulmányok rávilágítottak arra, hogy mely kognitív változókkal érdemes prediktív modelleket konstruálni, mert általuk magas pontossággal azonosíthatók az esetlegesen lemaradó hallgatók. Figyelemre méltó eredmény továbbá, hogy a kutatások nemcsak a vizsgált kurzus vagy STEM szak tudományterületén mérték az előzetes tudást és készségeket, hanem közvetett vagy közvetlen módon minden esetben megjelent a matematikai ismeretek, készségek fejlettségének vizsgálata is. Bár a tanulmányok keresése és kiválasztása a kognitív tényezők szerepének megismerésére irányult, számos nem-kognitív változóra is fény derült, melyek szignifikánsak lehetnek az egyetemi teljesítményt előre jelző modellekben. Prediktáló hatásuk feltárásához azonban szélesebb körű szakirodalmi áttekintés szükséges.

Tanulmányunk az előrejelző modellek típusairól, pontosságáról is ad egy átfogó képet, ami alapján elmondható, hogy a modern statisztika eszközei számos lehetőséget adnak modellek készítésére. Univerzális választás azonban nincs, a feltárt kutatásokban konstruált előre jelző modellek megbízhatósága széles intervallumban mozog. Érdemes ezért az adatelemzés során a függő és a független változók közötti kapcsolat megállapítására többféle modellt készíteni, illetve a modelleket tesztelni, és minél nagyobb előrejelzési pontosságot elérni. Kutatásunk

további tanulsága, hogy lényeges szem előtt tartani az eredmények általánosíthatóságának kérdését, a különböző kultúrákban, oktatási rendszerekben, különböző modellezési technikával végzett kutatások összehasonlíthatóságát. A kérdés fontosságát egy példával szemléltetjük: ha a kutatások ugyanazon országban, ugyanazon mérőeszközzel zajlanak is, vagyis a kutatók ugyanazon adathoz jutnak (pl. *MUST* összpontszáma), ezen adat nem feltétlenül ily módon kerül be a modellbe (intervallumok szerint felosztva, három kategóriájú változó, lásd K. S. Lee et al., 2023; 0 – 20 skála, lásd Williamson et al., 2020). Tehát megegyező mérőeszközök esetén sem feltétlenül kapunk összehasonlítható előre jelző modelleket.

Szakirodalmi összefoglalónk limitációja, hogy tanulmányokat kizárólag a Scopus adatbázisában kerestünk, így az ott nem szereplő tanulmányok nem kerülhettek áttekintésre. A beválogatott tanulmányok keletkezési idejét az elmúlt 30 évre korlátoztuk, de mint említettük, a témának ezt megelőzően is gazdag szakirodalma van. Az azonos, saját mérőeszközt alkalmazó vagy ugyanazon kutatócsoport munkáját tárgyaló cikkek felkutatásához hólabda-módszert alkalmaztunk, ami az egyik oka lehet annak, hogy az elemzésünkbe bevont tanulmányok döntő része az USA-ban készült. Végül pedig, hazai példákat is találhatunk a Scopusban az egyetemi sikeresség vizsgálatáról (l. pl. Kocsis & Molnár, 2023; Molnár & Kocsis, 2023; Nagy, 2023; Nagy & Molontay, 2023), de ezen tanulmányok a vizsgált felsőoktatási intézmény számos szakját együttesen kezelik, így ezek a cikkek nem kerültek be a szakirodalmi áttekintésbe. Eredményeink jelzik, hogy a vizsgált téma szisztematikus szakirodalmi áttekintést igényelne mind a kognitív, mind a nem-kognitív változók szerepének feltárására, de a szakirodalom rendkívüli gazdagsága miatt úgy véltük, hogy ez esetünkben nem lehetséges.

A későbbiekben szűkebb témakörökben, például egy-egy természettudományos diszciplína egyetemi tanulására vagy adott mérőeszközökre vonatkozóan további szisztematikus feltáró vizsgálatok végezhetők, kitágítva az adatbázisok körét, és esetlegesen leszűkítve az áttekintett időszakot. A tanulmányban közölt eredmények alapját képezhetik további, konkrét STEM területeken az előre jelző modellekre irányuló kutatásoknak, valamint hozzájárulhatnak az egyetemi lemorzsolódást csökkentő pedagógiai, módszertani fejlesztések kidolgozásához.

Irodalom

- Adkins, M., & Noyes, A. (2018). Do advanced mathematics skills predict success in biology and chemistry degrees? *International Journal of Science and Mathematics Education*, 16(3), 487–502. doi: [10.1007/s10763-016-9794-y](https://doi.org/10.1007/s10763-016-9794-y)
- Albaladejo, J. D. P., Broadway, S., Mamiya, B., Petros, A., Powell, C. B., Shelton, G. R., Walker, D. R., Weber, R., Williamson, V. M., & Mason, D. (2018). ConfChem conference on mathematics in undergraduate chemistry instruction: MUST-know pilot study–Math preparation study from Texas. *Journal of Chemical Education*, 95(8), 1428–1429. doi: [10.1021/acs.jchemed.8b00096](https://doi.org/10.1021/acs.jchemed.8b00096)
- Alvarez, N. L., Callejas, Z., & Griol, D. (2020). Predicting computer engineering students' dropout in Cuban higher education with pre-enrollment and early performance data. *Journal of Technology and Science Education*, 10(2), 241–258. doi: [10.3926/jotse.922](https://doi.org/10.3926/jotse.922)
- Alyahyan, E., & Düstegör, D. (2020). Predicting academic success in higher education: Literature review and best practices. *International Journal of Educational Technology in Higher Education*, 17(1), Article 3. doi: [10.1186/s41239-020-0177-7](https://doi.org/10.1186/s41239-020-0177-7)
- Binder, T., Sandmann, A., Sures, B., Friege, G., Theyssen, H., & Schmiemann, P. (2019). Assessing prior knowledge types as predictors of academic achievement in the introductory phase of biology and physics study programmes using logistic regression. *International Journal of STEM Education*, 6(1), Article 33. doi: [10.1186/s40594-019-0189-9](https://doi.org/10.1186/s40594-019-0189-9)

- Chariker, J., Ralston, P., Hieb, J., & Wilkins, C. (2013, June 23–26). *An analysis of two interventions designed to improve student performance in engineering calculus* [Conference presentation]. 2013 ASEE Annual Conference & Exposition, Atlanta, GA, United States. doi: [10.18260/1-2--19162](https://doi.org/10.18260/1-2--19162)
- Coley, N. R. (1973). Prediction of success in general chemistry in a community college. *Journal of Chemical Education*, 50(9), Article 613. doi: [10.1021/ed050p613](https://doi.org/10.1021/ed050p613)
- Cooper, C. I., & Pearson, P. T. (2012). A genetically optimized predictive system for success in general chemistry using a diagnostic algebra test. *Journal of Science Education and Technology*, 21(1), 197–205. doi: [10.1007/s10956-011-9318-z](https://doi.org/10.1007/s10956-011-9318-z)
- Cornog, J., & Stoddard, G. D. (1925). Predicting performance in chemistry. *Journal of Chemical Education*, 2(8), Article 701. doi: [10.1021/ed002p701](https://doi.org/10.1021/ed002p701)
- De Winter, J. C. F., & Dodou, D. (2011). Predicting academic performance in engineering using high school exam scores. *International Journal of Engineering Education*, 27(6), 1343–1351.
- Demko, P., Ventre, L. R., & Lester, D. (1985). Preliminary study of predicting performance in chemistry courses. *Psychological Reports*, 57(2), 514–514. doi: [10.2466/pr0.1985.57.2.514](https://doi.org/10.2466/pr0.1985.57.2.514)
- Di Martino, P., Gregorio, F., & Iannone, P. (2023). The transition from school to university in mathematics education research: *New trends and ideas from a systematic literature review*. *Educational Studies in Mathematics*, 113(1), 7–34. doi: [10.1007/s10649-022-10194-w](https://doi.org/10.1007/s10649-022-10194-w)
- Donovan, W. J., & Wheland, E. R. (2009). Comparisons of success and retention in a general chemistry course before and after the adoption of a mathematics prerequisite. *School Science and Mathematics*, 109(7), 371–382. doi: [10.1111/j.1949-8594.2009.tb17868.x](https://doi.org/10.1111/j.1949-8594.2009.tb17868.x)
- Gambini, A., Desimoni, M., & Ferretti, F. (2024). Predictive tools for university performance: An explorative study. *International Journal of Mathematical Education in Science and Technology*, 55(3), 691–717. doi: [10.1080/0020739X.2021.2022794](https://doi.org/10.1080/0020739X.2021.2022794)
- Graafsma, I. L., Robidoux, S., Nickels, L., Roberts, M., Polito, V., Zhu, J. D., & Marinus, E. (2023). The cognition of programming: Logical reasoning, algebra and vocabulary skills predict programming performance following an introductory computing course. *Journal of Cognitive Psychology*, 35(3), 364–381. doi: [10.1080/20445911.2023.2166054](https://doi.org/10.1080/20445911.2023.2166054)
- Hazari, Z., Tai, R. H., & Sadler, P. M. (2007). Gender differences in introductory university physics performance: The influence of high school physics preparation and affective factors. *Science Education*, 91(6), 847–876. doi: [10.1002/sc.20223](https://doi.org/10.1002/sc.20223)
- Hieb, J. L., Lyle, K. B., Ralston, P. A. S., & Chariker, J. (2015). Predicting performance in a first engineering calculus course: Implications for interventions. *International Journal of Mathematical Education in Science and Technology*, 46(1), 40–55. doi: [10.1080/0020739X.2014.936976](https://doi.org/10.1080/0020739X.2014.936976)
- Hovey, N. W., & Krohn, A. (1958). Predicting failures in general chemistry. *Journal of Chemical Education*, 35(10), Article 507. doi: [10.1021/ed035p507](https://doi.org/10.1021/ed035p507)
- Hovey, N. W., & Krohn, A. (1963). An evaluation of the Toledo chemistry placement examination. *Journal of Chemical Education*, 40(7), Article 370. doi: [10.1021/ed040p370](https://doi.org/10.1021/ed040p370)
- Huang, S., & Fang, N. (2013). Predicting student academic performance in an engineering dynamics course: A comparison of four types of predictive mathematical models. *Computers and Education*, 61(1), 133–145. doi: [10.1016/j.compedu.2012.08.015](https://doi.org/10.1016/j.compedu.2012.08.015)
- Jones, M. T., Barlow, A. E. L., & Villarejo, M. (2010). Importance of undergraduate research for minority persistence and achievement in biology. *The Journal of Higher Education*, 81(1), 82–115. <https://www.tandfonline.com/doi/abs/10.1080/00221546.2010.11778971>
- Kim, Y.-E., Yu, S. L., Koenka, A. C., Lee, H., & Heckler, A. F. (2022). Can self-efficacy and task values buffer perceived costs? *Exploring introductory- and upper-level physics courses*. *Journal of Experimental Education*, 90(4), 839–861. doi: [10.1080/00220973.2021.1878992](https://doi.org/10.1080/00220973.2021.1878992)
- King, N. C., & Hambrook, G. (2021). Examining the impact of pre-university qualifications on success in interdisciplinary science. *Journal of Further and Higher Education*, 45(9), 1192–1205. doi: [10.1080/0309877X.2020.1854695](https://doi.org/10.1080/0309877X.2020.1854695)
- Kocsis, Á., & Molnár, Gy. (2023). A felvételi pontszám előrejelző ereje az egyetemi sikerességre: Egy nagymintás longitudinális kutatás eredményei. *Iskolakultúra*, 33(12), 46–62. doi: [10.14232/iskkult.2023.12.46](https://doi.org/10.14232/iskkult.2023.12.46)

- Kocsis, Á., & Molnár, Gy. (2024). Factors influencing academic performance and dropout rates in higher education. *Oxford Review of Education*, 1–19. doi: [10.1080/03054985.2024.2316616](https://doi.org/10.1080/03054985.2024.2316616)
- Kohen, Z., & Nitzan, O. (2022). Excellence in mathematics in secondary school and choosing and excelling in STEM professions over significant periods in life. *International Journal of Science and Mathematics Education*, 20(1), 169–191. doi: [10.1007/s10763-020-10138-x](https://doi.org/10.1007/s10763-020-10138-x)
- Kolopajlo, L. (2019). Attitudinal and mathematical assessments as measures of student success in a college general chemistry II course. *Ohio Journal of Science*, 119(2), 17–27. doi: [10.18061/ojs.v119i2.6626](https://doi.org/10.18061/ojs.v119i2.6626)
- Kreiser, R. P., Wright, A. K., McKenzie, T. L., Albright, J. A., Mowles, E. D., Hollows, J. E., Limbocker, S., Eslinger, M., Limbocker, R., & Nguyen, L. T. (2022). Utilization of standardized college entrance metrics to predict undergraduate student success in chemistry. *Journal of Chemical Education*, 99(4), 1725–1733. doi: [10.1021/acs.jchemed.1c00719](https://doi.org/10.1021/acs.jchemed.1c00719)
- Lee, K. S., Rix, B., & Spivey, M. Z. (2023). Predictions of success in organic chemistry based on a mathematics skills test and academic achievement. *Chemistry Education Research and Practice*, 24(1), 176–191. doi: [10.1039/D2RP00140C](https://doi.org/10.1039/D2RP00140C)
- Lee, Y.-K., Freer, E., Robinson, K. A., Perez, T., Lira, A. K., Briedis, D., Walton, S. P., & Linnenbrink-Garcia, L. (2022). The multiplicative function of expectancy and value in predicting engineering students' choice, persistence, and performance. *Journal of Engineering Education*, 111(3), 531–553. doi: [10.1002/jee.20456](https://doi.org/10.1002/jee.20456)
- Legg, M. J., Legg, J. C., & Greenbowe, T. J. (2001). Analysis of success in general chemistry based on diagnostic testing using logistic regression. *Journal of Chemical Education*, 78(8), Article 1117. doi: [10.1021/ed078p1117](https://doi.org/10.1021/ed078p1117)
- Leopold, D. G., & Edgar, B. (2008). Degree of mathematics fluency and success in second-semester introductory chemistry. *Journal of Chemical Education*, 85(5), 724. doi: [10.1021/ed085p724](https://doi.org/10.1021/ed085p724)
- Lewis, S. E., & Lewis, J. E. (2007). Predicting at-risk students in general chemistry: Comparing formal thought to a general achievement measure. *Chemistry Education Research and Practice*, 8(1), 32–51. doi: [10.1039/B6RP90018F](https://doi.org/10.1039/B6RP90018F)
- Loehr, J. F., Almarode, J. T., Tai, R. H., & Sadler, P. M. (2012). High school and college biology: A multi-level model of the effects of high school courses on introductory course performance. *Journal of Biological Education*, 46(3), 165–172. doi: [10.1080/00219266.2011.617767](https://doi.org/10.1080/00219266.2011.617767)
- MacPhail, A. H., & Foster, L. S. (1939). Placement in beginning chemistry courses at Brown University. *Journal of Chemical Education*, 16(6), Article 270. doi: [10.1021/ed016p270](https://doi.org/10.1021/ed016p270)
- McFate, C., & Olmsted, J. I. (1999). Assessing student preparation through placement tests. *Journal of Chemical Education*, 76(4), Article 562. doi: [10.1021/ed076p562](https://doi.org/10.1021/ed076p562)
- Molnár, Gy., & Kocsis, Á. (2023). Cognitive and non-cognitive predictors of academic success in higher education: A large-scale longitudinal study. *Studies in Higher Education*, 49(9), 1610–1624. doi: [10.1080/03057079.2023.2271513](https://doi.org/10.1080/03057079.2023.2271513)
- Nadelson, L. S., & Seifert, A. L. (2017). Integrated STEM defined: Contexts, challenges, and the future. *The Journal of Educational Research*, 110(3), 221–223. doi: [10.1080/00220671.2017.1289775](https://doi.org/10.1080/00220671.2017.1289775)
- Nagy M. (2023). Lemorzsolódás előrejelzése személyre szabott értelmezhető gépi tanulási módszerek segítségével. *Scientia et Securitas*, 3(3), 270–281. doi: [10.1556/112.2022.00107](https://doi.org/10.1556/112.2022.00107)
- Nagy, M., & Molontay, R. (2023). Interpretable dropout prediction: Towards XAI-based personalized intervention. *International Journal of Artificial Intelligence in Education*, 34, 274–300. doi: [10.1007/s40593-023-00331-8](https://doi.org/10.1007/s40593-023-00331-8)
- Nakakoji, Y., & Wilson, R. (2018). First-year mathematics and its application to science: Evidence of transfer of learning to physics and engineering. *Education Sciences*, 8(1), Article 8. doi: [10.3390/educsci8010008](https://doi.org/10.3390/educsci8010008)
- National Science Foundation. (1996). *Shaping the future: New expectations for undergraduate education in science, mathematics, engineering, and technology* (ED404158). National Science Foundation. <https://files.eric.ed.gov/fulltext/ED404158.pdf>

- Nguyen, T.-L. K., Williams, A., & Ludwikowski, W. M. A. (2017). Predicting student success and retention at an HBCU via interest-major congruence and academic achievement. *Journal of Career Assessment*, 25(3), 552–566. doi: [10.1177/1069072716651870](https://doi.org/10.1177/1069072716651870)
- Nolte, N., Fleischer, J., Spoden, C., & Leutner, D. (2024). Cross-disciplinary impact of spatial visualization ability on study success in higher education. *Journal of Educational Psychology*. Advance online publication. doi: [10.1037/edu0000847](https://doi.org/10.1037/edu0000847)
- Nurudeen, A. H., Fakhrou, A., Lawal, N., & Ghareeb, S. (2023). Academic performance of engineering students: A predictive validity study of first-year GPA and final-year CGPA. *Engineering Reports*, 6(5), Article e12766. doi: [10.1002/eng2.12766](https://doi.org/10.1002/eng2.12766)
- OECD. (2022). *Education at a Glance 2022: OECD Indicators*. OECD Publishing. doi: [10.1787/3197152b-en](https://doi.org/10.1787/3197152b-en)
- OECD. (2023). *Education at a Glance 2023: OECD Indicators*. OECD Publishing. doi: [10.1787/e13bef63-en](https://doi.org/10.1787/e13bef63-en)
- Ortiz-Lozano, J. M., Rua-Vieites, A., Bilbao-Calabuig, P., & Casadesús-Fa, M. (2020). University student retention: Best time and data to identify undergraduate students at risk of dropout. *Innovations in Education and Teaching International*, 57(1), 74–85. doi: [10.1080/14703297.2018.1502090](https://doi.org/10.1080/14703297.2018.1502090)
- Pinxten, M., Van Soom, C., Peeters, C., De Laet, T., & Langie, G. (2019). At-risk at the gate: Prediction of study success of first-year science and engineering students in an open-admission university in Flanders—any incremental validity of study strategies? *European Journal of Psychology of Education*, 34(1), 45–66. doi: [10.1007/s10212-017-0361-x](https://doi.org/10.1007/s10212-017-0361-x)
- Potgieter, M., Ackermann, M., & Fletcher, L. (2010). Inaccuracy of self-evaluation as additional variable for prediction of students at risk of failing first-year chemistry. *Chemistry Education Research and Practice*, 11(1), 17–24. doi: [10.1039/c001042c](https://doi.org/10.1039/c001042c)
- Potgieter, M., Davidowitz, B., & Venter, E. (2008). Assessment of preparedness of first-year chemistry students: Development and application of an instrument for diagnostic and placement purposes. *African Journal of Research in Mathematics, Science and Technology Education*, 12, 1–17. doi: [10.1080/10288457.2008.10740638](https://doi.org/10.1080/10288457.2008.10740638)
- Powell, C. B., Simpson, J., Williamson, V. M., Dubrovskiy, A., Walker, D. R., Jang, B., Shelton, G. R., & Mason, D. (2020). Impact of arithmetic automaticity on students' success in second-semester general chemistry. *Chemistry Education Research and Practice*, 21(4), 1028–1041. doi: [10.1039/D0RP00006J](https://doi.org/10.1039/D0RP00006J)
- Russell, A. A. (1994). A rationally designed general chemistry diagnostic test. *Journal of Chemical Education*, 71(4), Article 314. doi: [10.1021/ed071p314](https://doi.org/10.1021/ed071p314)
- Sadler, P. M., & Tai, R. H. (2001). Success in introductory college physics: The role of high school preparation. *Science Education*, 85(2), 111–136. doi: [10.1002/1098-237X\(200103\)85:2<111::AID-SCE20>3.0.CO;2-O](https://doi.org/10.1002/1098-237X(200103)85:2<111::AID-SCE20>3.0.CO;2-O)
- Sadler, P. M., & Tai, R. H. (2007). The two high-school pillars supporting college science. *Science*, 317(5837), 457–458. doi: [10.1126/science.1144214](https://doi.org/10.1126/science.1144214)
- Shelton, G. R., Mamiya, B., Weber, R., Rush Walker, D., Powell, C. B., Jang, B., Dubrovskiy, A. V., Villalta-Cerdas, A., & Mason, D. (2021). Early warning signals from automaticity diagnostic instruments for first- and second-semester general chemistry. *Journal of Chemical Education*, 98(10), 3061–3072. doi: [10.1021/acs.jchemed.1c00714](https://doi.org/10.1021/acs.jchemed.1c00714)
- Spencer, H. E. (1996). Mathematical SAT test scores and college chemistry grades. *Journal of Chemical Education*, 73(12), Article 1150. doi: [10.1021/ed073p1150](https://doi.org/10.1021/ed073p1150)
- Stitzel, S., & Raje, S. (2022). Understanding diverse needs and access to resources for student success in an introductory college chemistry course. *Journal of Chemical Education*, 99(1), 49–55. doi: [10.1021/acs.jchemed.1c00381](https://doi.org/10.1021/acs.jchemed.1c00381)
- Tai, R. H., & Sadler, P. M. (2007). Chemical education research: High school chemistry instructional practices and their association with college chemistry grades. *Journal of Chemical Education*, 84(6), 1040–1046. doi: [10.1021/ed084p1040](https://doi.org/10.1021/ed084p1040)
- Tai, R. H., Sadler, P. M., & Loehr, J. F. (2005). Factors influencing success in introductory college chemistry. *Journal of Research in Science Teaching*, 42(9), 987–1012. doi: [10.1002/tea.20082](https://doi.org/10.1002/tea.20082)

- Tai, R. H., Ward, R. B., & Sadler, P. M. (2006). High school chemistry content background of introductory college chemistry students and its association with college chemistry grades. *Journal of Chemical Education*, 83(11), 1703–1711. doi: [10.1021/ed083p1703](https://doi.org/10.1021/ed083p1703)
- Thompson, E. D., Bowling, B. V., & Markle, R. E. (2018). Predicting student success in a major's introductory biology course via logistic regression analysis of scientific reasoning ability and mathematics scores. *Research in Science Education*, 48(1), 151–163. doi: [10.1007/s11165-016-9563-5](https://doi.org/10.1007/s11165-016-9563-5)
- Van der Zanden, P. J. A. C., Denessen, E., Cillessen, A. H. N., & Meijer, P. C. (2018). Domains and predictors of first-year student success: A systematic review. *Educational Research Review*, 23, 57–77. doi: [10.1016/j.edurev.2018.01.001](https://doi.org/10.1016/j.edurev.2018.01.001)
- Velázquez, J. S., Cavas, F., Fuentes, M. C., & García-Ros, R. (2023). Educational pathways, spatial skills, and academic achievement in graphic expression in first year of engineering. *Education Sciences*, 13(7), Article 756. doi: [10.3390/educsci13070756](https://doi.org/10.3390/educsci13070756)
- Vincent-Ruz, P., Binning, K., Schunn, C. D., & Grabowski, J. (2018). The effect of math SAT on women's chemistry competency beliefs. *Chemistry Education Research and Practice*, 19(1), 342–351. doi: [10.1039/c7rp000137a](https://doi.org/10.1039/c7rp000137a)
- Vyas, V. S., Kemp, B., & Reid, S. A. (2021). Zeroing in on the best early-course metrics to identify at-risk students in general chemistry: An adaptive learning pre-assessment vs. traditional diagnostic exam. *International Journal of Science Education*, 43(4), 552–569. doi: [10.1080/09500693.2021.1874071](https://doi.org/10.1080/09500693.2021.1874071)
- Wagner, E. P., Sasser, H., & DiBiase, W. J. (2002). Predicting students at risk in general chemistry using pre-semester assessments and demographic information. *Journal of Chemical Education*, 79(6), Article 749. doi: [10.1021/ed079p749](https://doi.org/10.1021/ed079p749)
- Whitcomb, K. M., Kalender, Z. Y., Nokes-Malach, T. J., Schunn, C. D., & Singh, C. (2020). Engineering students' performance in foundational courses as a predictor of future academic success. *International Journal of Engineering Education*, 36(4), 1340–1355.
- Willems, J., Coertjens, L., Tambuyzer, B., & Donche, V. (2019). Identifying science students at risk in the first year of higher education: The incremental value of non-cognitive variables in predicting early academic achievement. *European Journal of Psychology of Education*, 34(4), 847–872. doi: [10.1007/s10212-018-0399-4](https://doi.org/10.1007/s10212-018-0399-4)
- Williamson, V. M., Walker, D. R., Chuu, E., Broadway, S., Mamiya, B., Powell, C. B., Shelton, G. R., Weber, R., Dabney, A. R., & Mason, D. (2020). Impact of basic arithmetic skills on success in first-semester general chemistry. *Chemistry Education Research and Practice*, 21(1), 51–61. doi: [10.1039/C9RP00077A](https://doi.org/10.1039/C9RP00077A)
- Willis, W. K., Williamson, V. M., Chuu, E., & Dabney, A. R. (2022). The relationship between a student's success in first-semester general chemistry and their mathematics fluency, profile, and performance on common questions. *Journal of Science Education and Technology*, 31, 1–15. doi: [10.1007/s10956-021-09927-y](https://doi.org/10.1007/s10956-021-09927-y)
- Worthley, M. R., Gloeckner, G. W., & Kennedy, P. A. (2016). A mixed-methods explanatory study of the failure rate for freshman STEM calculus students. *PRIMUS*, 26(2), 125–142. doi: [10.511970.2015.1067265](https://doi.org/10.511970.2015.1067265)
- Xu, X., Villafane, S. M., & Lewis, J. E. (2013). College students' attitudes toward chemistry, conceptual knowledge and achievement: Structural equation model analysis. *Chemistry Education Research and Practice*, 14(2), 188–200. doi: [10.1039/C3RP20170H](https://doi.org/10.1039/C3RP20170H)

ABSTRACT

METHODS FOR EXPLORING COGNITIVE FACTORS PREDICTING ACADEMIC PERFORMANCE IN STEM MAJORS AND COURSES – A NARRATIVE REVIEW

Fruzsina D. Nagy & Erzsébet Korom

Keywords: dropout in higher education, STEM, predictive model, cognitive variables

There is a strong demand in the labour market for STEM major graduates (science, computer science, engineering and mathematics), both at national and international level. However, only a small proportion of undergraduates (23% on average) study in these fields, and many of them drop out, with only 56% of them graduating with a STEM degree (OECD, 2023). With the aim of reducing drop-out in higher education, a growing body of research is developing predictive models to prospectively identify students likely to be left behind. The aim of our narrative literature review was to identify cognitive variables (e.g., high school studies, prior knowledge) that have been found to have significant effects in existing predictive models of STEM majors or courses; thus, they may be worth further investigation in future research and may be the basis for catch-up programmes. From the very rich literature available, we have reviewed the last 30 years. The main findings of our exploration are that (1) while subject knowledge of a particular subject or course plays a more diverse role, the role of mathematics appears in all research; (2) the complexity of models constructed in existing research is highly varied, ranging from descriptive statistics to machine learning; (3) in some models, it was not the cognitive variables that had the largest effect, but some non-cognitive variables; and (4) a lesson for future research is that models need not only to be constructed, but also tested on a subset of the sample. The results reported in this study may form the basis of further systematic literature reviews in specific STEM fields, as well as contribute to the preparation of pedagogical and methodological developments to reduce dropout rates at university level.

Magyar Pedagógia, 124(4). 239–262. (2024)
doi: 10.14232/mped.2024.4.239

D. Nagy Fruzsina:  <https://orcid.org/0009-0006-1794-7606>
Szegedi Tudományegyetem Neveléstudományi Doktori Iskola
H-6722, Szeged, Petőfi Sándor sgt. 32–34.
d.nagy.fruzsina@edu.u-szeged.hu

Korom Erzsébet:  <https://orcid.org/0000-0001-9534-8146>
Szegedi Tudományegyetem Neveléstudományi Intézet; MTA-SZTE Digitális Tanulási Technológiák Kutatócsoport
H-6722, Szeged, Petőfi Sándor sgt. 32–34.
korom@edpsy.u-szeged.hu