

Bridging the Gap: Advancing Finite Element Analysis in Numerical Simulation – 1. rész: Miért aktuális ez a könyv most?

AI, digitális transzformáció, digitális ikrek és explainable AI

Part 1: Why Is This Book Relevant Now?

Mi változott a mérnöki munka környezetében?

Szabó Barna *Bridging the Gap: Advancing Finite Element Analysis in Numerical Simulation* című könyve [1] egy gyakorlati különbséget állít a középpontba: egy számítás végrehajtása és az eredmény megbízhatóságának alátámasztása nem ugyanaz a feladat. A címben szereplő *rész* a módszer mérnöki és alkalmazott matematikai értelmezése között húzódik. A szerző közös fogalmi alapot keres ahhoz, hogy a szoftverben elvégezhető műveleteket összekössük azzal, amit a modellről és a számított mennyiségekről valóban állíthatunk [1: 5-7. o.].

A kötet gondolatait korábbi könyvismertetőnkben már bemutattuk [2]. Most azt a kérdést tesszük fel, miért érdemes ezekhez visszatérni az AI térnyerése idején. Szabó maga is az AI-integráció miatt sürgeti a modellezési gyakorlat felülvizsgálatát. Figyelmeztetése azonban nem egyszerűen az új eszközök kockázataira vonatkozik: a könyv a mérnöki tudás szervezéséről, az előrejelzések javításáról és a modellek folyamatos fejlesztéséről is szól [1: 5-7. és 41-45. o.].

Az új helyzetet az teremti, hogy a digitális eszközök egyre több ponton kapcsolódhatnak be a munkánkba. Felismerhetnek eltéréseket a vizsgálati képen, adatokat emelhetnek ki egy dokumentumból, új anyagösszetételeket és kristályszerkezeteket javasolhatnak, vagy a következő művelet végrehajtásához használhatnak más eszközöket [3-6]. Nem ugyanarról az AI-ról és nem azonos érettségű alkalmazásokról van szó. A közös változás az, hogy a feladat végrehajtása mellett a megoldáskeresés és a munkamegosztás egy része is automatizálhatóvá válik.

Éppen ezért éleződik ki a könyv kérdése: hogyan lesz a géppel előállított eredményből mérnöki tudás? Nem minden automatizált lépés teremt új ismeretet, és nem minden hasznos gépi javaslat alkalmas közvetlenül döntésre. Különbséget kell tennünk az adat kiolvasása, a modellből származó becslés és a felhasználási célra vonatkozó következtetés között. Közben azt is fel kell ismernünk, milyen új kérdések válnak vizsgálhatóvá a gyorsabb feldolgozás és a bővülő számítási lehetőségek révén.

A könyv aktualitását ebben a kettősségben látjuk. Az AI több változat kipróbálását és több adat együttes értelmezését teheti lehetővé, miközben a munkát végző szakember kevésbé láthat rá minden köztes lépésre. A cél nem ennek a változásnak a fékezése, hanem olyan munkamegosztás kialakítása, amelyben a gyorsaság a jobb megismerést és a megalapozottabb döntést szolgálja.

A válaszgenerálástól a felfedezés támogatásáig

A könyv pontos fogalomhasználatot sürgető gondolata az AI esetében is hasznos [1: 9-13. o.]. Egy radiográfiai képen eltéréseket felismerő modell, egy dokumentációban kereső nyelvi asszisztens és egy előre megadott karbantartási szabályt végrehajtó algoritmus eltérő feladatot lát el. Az utóbbi önmagában nem is feltétlenül AI. A fejlesztésről érdemben akkor tudunk beszélni, ha megnevezzük, mit bízunk a tanult összefüggésekre, mit az előre rögzített szabályokra, és hol marad szükség szakértői döntésre [3, 6]. Az 1. táblázat a cikkben tárgyalt funkciókat és a hozzájuk tartozó mérnöki kérdéseket foglalja össze.

1. táblázat: Eltérő funkciók az AI-val támogatott mérnöki munkában

Funkció	Kapcsolódó példa és lehetőség	Tisztázandó kérdés
Dokumentumadatok kinyerése	Műszaki rajzok táblázatainak felismerése és rekonstrukciója [6]	Megmaradt-e az adat jelentése és berendezéshez tartozása?
Vizsgálati képek gépi kiértékelése	Radiográfiai képek eltéréseinek felismerése és osztályozása [3]	Mely eltéréseket találja meg a modell, és melyeket téveszti el?
Szabályalapú értékelés	Elfogadási feltételek és karbantartási szabályok alkalmazása [3, 6]	Helyes adatokra és megfelelő szabályra épül-e? Önmagában nem AI.
Generatív anyagtervezés	MatterGen: lehetséges anyagösszetételek és kristályszerkezetek létrehozása [4]	Milyen számítás és kísérlet igazolhatja a javasolt anyag alkalmasságát?
Tanított közelítő modell	Neurális operátor áramlási számítások gyors közelítésére [8]	Mit közelít, milyen hibával és mely alkalmazási tartományban?
Eszközhasználó AI-ügynök	Eigen Engineering Agent: összekapcsolt konfigurálási és programozási lépések végrehajtása [11, 12]	Mi a feladat és az ellenőrzés határa, mit hagy jóvá a mérnök?

A generálás lehetősége az anyagtervezésben különösen érdekes: a keresés a kívánt tulajdonságból indulhat a lehetséges összetételek és kristályszerkezetek felé. Zeni és munkatársai MatterGen-moddal ilyen szerkezetváltozatokat állít elő számítógépen: arra ad javaslatot, hogy milyen atomokból és milyen térbeli elrendeződésben épülhetne fel a keresett szeretlen anyag. Ezek még nem előállított és minősített anyagok, hanem további számításra és kísérleti vizsgálatra szánt javaslatok. A 2025-ös közleményben a kutatók az egyik javasolt szerkezet alapján anyagot állítottak elő és annak tulajdonságait is vizsgálták [4]. Ebben nem az a szokatlan, hogy a számítógéppel javasolt anyagot végül kísérletileg is meg kell vizsgálni – ez az anyagfejlesztés természetes része. Az új lehetőség az, hogy az AI a rendkívül nagy kombinációs térből maga is képes ígéretes összetételeket és kristályszerkezeteket javasolni, amelyeket azután számításokkal és kísérletekkel lehet tovább szűri és ellenőrizni.

Jó példa erre a Johns Hopkins Egyetemen kialakított AIMD-L (Artificial Intelligence for Materials Design Laboratory) [5], amelyben különböző anyagvizsgálati és anyagjellemzési eljárásokat robotizált mintakezeléssel és közös adatfeldolgozó rendszerrel kapcsolták össze. A laboratóriumban többek között röntgendiffrakciós és

röntgenfluoreszcens vizsgálatok, nanoindentáció és nagy sebességű dinamikus anyagvizsgálatok végezhetőek automatizált munkafolyamatban. A kísérleteket központi vezérlőrendszer koordinálja, amely emberi kezelőtől vagy AI-ügynöktől is fogadhat utasításokat, a feldolgozott mérési eredmények pedig felhasználhatók a következő vizsgálati lépés meghatározásához. A példa számunkra azért fontos, mert a javaslat, a kísérlet és az értékelés rövidebb, összekapcsolt ciklusainak lehetőségét mutatja.

Ezek alapján az AI szerepét szűken írni le, ha kizárólag a rutinfeladatok gyorsításáról beszélünk. Meghatározott feladatokban a lehetséges megoldások kereséséhez is hozzá tud járulni. Mérnöki szempontból ennek az a jelentősége, hogy sok lehetséges anyagösszetétel és szerkezetváltozat közül kiválaszthatók a részletes számításra vagy kísérletre érdemes megoldások. Az így felvetett ötlet értékét a következő számítás, kísérlet vagy összehasonlítás dönti el, nem az, hogy ember vagy algoritmus javasolta.

A könyv ennél tartósabb kiindulópontot is kínál: a modellfejlesztést új adatokra és új hipotézisekre nyitott tevékenységnek tekinti [1: 41-45. o.]. Ezt az AI-ra is alkalmazhatjuk. Nem azt kell előre eldöntenünk, mire lesz mindig képtelen, hanem azt kell vizsgálnunk, hogy az adott fejlesztés mit tett lehetővé, és milyen ellenőrzés mellett használható az eredménye.

Digitális transzformáció: az egyéni segítségtől a közös munkafolyamatig

Szabó professzor a digitális transzformáció eredményét a numerikus szimulációban a matematikai modellek előrejelző képességének javulásához kapcsolja [1: 68-72. o.]. Az anyagvizsgálatban ehhez az adatfeldolgozás és a szakértői munka összekapcsolásának kérdése társul. Egy jól működő felismerő algoritmus önmagában még nem mondja meg, hogyan kerül az eredménye a vizsgálati értékelésbe, milyen további információkkal kell összekapcsolni, és ki milyen feltételekkel használhatja fel. A digitális transzformáció ezért nem egyszerűen egyes munkalépések digitalizálását jelenti: a teljes mérnöki munkafolyamat átalakulását is magával hozhatja.

Erre az automatizálástechnikában már konkrét példát ad a Siemens 2026 áprilisában bemutatott Eigen Engineering Agent rendszere. Az AI-ügynök a Siemens TIA Portal (Totally Integrated Automation Portal) mérnöki szoftverkörnyezetéhez kapcsolódik. A TIA Portal az ipari automatizálási rendszerek tervezésének integrált környezete: egy projekten belül kezelhetők például a programozható logikai vezérlők (PLC-k), a gép és az ember közötti kezelői felületek (HMI-k), a hajtások, valamint az ezekhez kapcsolódó konfigurációs, programozási, tesztelési és diagnosztikai feladatok [11].

Az Eigen Engineering Agent jelentősége abban áll, hogy ebben a környezetben már nem pusztán szöveges javaslatokat ad. A Siemens leírása szerint értelmezi az adott TIA Portal-projekt adatszerkezetét, funkcióblokkjait, paramétereit és a komponensek közötti kapcsolatokat. Ezek alapján vezérlőprogramot hozhat létre vagy módosíthat, HMI-funkciókat alakíthat ki, illetve eszközök konfigurálásában

vehet részt. Az összetettebb feladatot lépésekre bontja, végrehajtja, majd az eredményt a projekt követelményéhez viszonyítva ellenőrzi és szükség esetén módosítja, mielőtt azt a mérnök felülvizsgálja [11].

A 2026 júniusában bemutatott további képességek ezt a működésmódot a munkafolyamat korábbi szakaszaira is kiterjesztik. Az egyik fejlesztés elektromos tervezési adatokból képes eszközöket és kapcsolatokat azonosítani, azokat a TIA Portal-projektbe átvinni, valamint a tényleges hardverfelépítéshez kapcsolódó PLC-változókat létrehozni. Egy másik funkció természetes nyelven megadott gépleírásból a Siemens Automation Framework szerinti projektszerkezetet állít elő [12]. Így az elektromos tervezés, a hardverkonfiguráció és a vezérlőszoftver kialakítása közötti, korábban részben manuális adatátadás egy része is AI-val támogatott munkafolyamatba kerül.

A példa jelentősége ezért túlmutat azon, hogy az AI gyorsabban képes programkódot előállítani. Ugyanazon mérnöki projekt több eleméhez és több egymásra épülő munkafázisához fér hozzá, ezért az egyes részfeladatok támogatásától a mérnöki folyamat részbeni végrehajtása és összehangolása felé mozdul el. A Siemens dokumentált képességei jelenleg az ipari automatizálási projektek meghatározott feladataira vonatkoznak; ebből nem következik, hogy az AI önállóan kezelne egy összetett mérnöki rendszer teljes életciklusát. A tendencia azonban jól látható.

Ha ez a működésmód más mérnöki szakterületeken is elterjed, az nem egyszerűen gyorsabbá teheti a jelenlegi munkát, hanem magát a munkamegosztást is átalakíthatja. A mérnök szerepe a részlépések közvetlen elvégzése mellett egyre inkább a célok, a korlátok és az elfogadási feltételek meghatározására, a létrehozott megoldások összevetésére és a teljes folyamat szakmai felügyeletére helyeződhet át. Ez közvetlenül kapcsolódik Szabó kérdésfelvetéséhez is: *milyen feladatot bízhatunk egy digitális eszközre, és milyen alapon fogadhatjuk el az eredményét?*

Korábbi, munkatársainkkal közösen végzett radiográfiai fejlesztésünkben hegesztett kötések röntgenfelvételeinek kiértékelését és az eredmények digitális rögzítését kellett összekapcsolnunk. Az elkészült alkalmazás az eltérések gépi felismerését, osztályozását és geometriai jellemzését szabványkövetelmények szerinti értékeléssel kapcsolta össze. A szakértő javíthatta a képen megjelenő eltérések jelöléseit, majd jóváhagyhatta az eredményt; a gépi és a módosított elemzés külön visszakereshető maradt a rendszerben. A korrigált képek a további tanításhoz is felhasználhatók voltak. E munkát az Anyagvizsgálók Lapja 2023/IV. számában ismertettük [3].

Számunkra a munka egyik tanulsága, hogy az eltérés felismerése, geometriai jellemzése és megengedhetőségének értékelése három különböző feladat. A képfelismerő modell, az alkalmazásra választott követelmény és a szakértői értékelés eltérő szerepet tölt be. Ezért az automatizálás eredményét sem elegendő csupán a felismerés alapján megítélni: a teljes értékelési folyamat használhatósága számít. A kérdés itt is az, amit Szabó professzor a szimuláció felől tesz fel: *mit állítunk az eredményről és milyen alapon támaszkodunk rá?*

Szabó professzor intelligens szimulációs alkalmazásokról szóló fejezete ehhez kínál mérnöki előképet. A Sim App szakértők által kialakított, ismétlődő számítási feladatokat egységesítő alkalmazás, amely a modellt és a hozzá tartozó eljárást más felhasználók számára is hozzáférhetővé teszi [1: 131-134. o.]. Egy ilyen alkalmazásnak önmagában nem kell mesterséges intelligenciát használnia. Az AI megjelenésével azonban új lehetőség nyílik: egy eszközhasználó AI-rendszer a feladat egyes részeit meglévő, ellenőrzött mérnöki alkalmazásokhoz irányíthatja. Ebben a modellben nem szükséges minden szakmai szabályt és fizikai összefüggést magába az AI-modellbe „beletanítani”; az AI a megfelelő mérnöki eszközt használhatja a feladathoz.

Saját munkánkban hasonló kérdéssel találkoztunk a műszaki dokumentumok feldolgozásakor. A feladat az volt, hogy régi berendezésrajzokon és adatlapokon szereplő műszaki információkat a kézi újragépelés helyett kereshető, szerkeszthető és az adott berendezéshez rendelhető adatokká alakítsuk. A kidolgozott eljárás felismeri a táblázatok szerkezetét, elkülöníti a sorokat és oszlopokat, szövegfelismeréssel kiolvassa a cellák tartalmát, majd az eredményt szerkeszthető adattáblába rendezi. Így például a tervezési nyomás, a hőmérséklet, az anyagnegnevezés és más berendezésadatok is strukturált formába kerülhetnek [6]. Az alábbi ábra egy műszaki adatlap részletén mutatja a táblázatszerkezet felismerését és az abból kinyert adatokat.

a) A táblázatszerkezet felismerése

DESIGN DATA/ MŰSZAKI ADATOK			
	Shell Side / Köpenyter	Tube Side / Csőtér	
Design Pressure (gauge) / Tervezési nyomás	barg	40	28
Design Temperature / Tervezési hőmérséklet	°C	-20/+150	-20/+150
Test Pressure (gauge) / Próbanyomás	barg	62.5	43.75
Steam out condition on shell side	6.8 barg/170°C		
Corrosion Allowance / Korrozíós pótlék	mm	1	3
Joint Efficiency / Hegesztési tényező		0.85	0.85
Density of Liquid / Közeg sűrűsége	kg/m ³	618	996

b) A szövegfelismerés után kapott adattábla

DESIGN DATA/MUSZAKIADATOK			
	Shell Side/Köpenyter	Tube Side/Csótér	
Design Pressure(gauge)/Tervezési nyomás	40	28	
Design Temperature / Tervezési hőmérséklet °C	-20/+150	-20/+150	
Test Pressure (gauge)/Próbanyomás	62.5 2	43.75 2	
Steam out condition on shell side	6.8 barg/170°C		
Corrosion Allowance /Korrozíós pótlék mm	1	3	
Joint Efficiency/Hegesztési tényező	0.85	0.85	
Density of Liquid / Kozeg sűrűsége kg/m3	618	996	

Műszaki adatlap feldolgozása: a) a sorok és oszlopok felismerése az eredeti rajzon; b) a szövegfelismerés után kapott, még ellenőrzendő adattábla [6]

A kiolvasott adatok a felületen ellenőrizhetők, javíthatók és kiegészíthetők, a módosítások pedig visszakövethetők. Az ábrán például a próbanyomás mellett szereplő, háromszögbe írt szám a szövegfelismerés eredményében a nyomásérték mellé került. A karakterek felismerése tehát még nem azonos a műszaki tartalom megértésével: el kell dönteni, melyik szám a mért vagy előírt fizikai mennyiség, mi a mértékegysége, és melyik csupán rajzi vagy hivatkozási jelölés. Ezért az eredeti forrást, a műszaki jelentést és az ellenőrzés lehetőségét is meg kell őrizni.

Egy következő lépésben már elképzelhető olyan AI-alapú asszisztens vagy ügynök, amely nemcsak adatot

olvas ki a dokumentumból, hanem megkeresi a feladathoz szükséges további információt, kiválasztja a megfelelő értékelő eljárást vagy meghív egy erre kialakított mérnöki alkalmazást. A cél ebben az esetben sem az, hogy a nyelvi modell maga találja ki a műszaki szabályt, hanem hogy ellenőrzött adatokhoz és ellenőrzött szakmai eszközökhöz kapcsolja össze a munkafolyamat megfelelő lépéseit.

A digitális transzformáció eredményességét ezért nem kizárólag egy algoritmus pontosságával vagy egy részfeladat végrehajtási idejével érdemes mérni. Az átfutási idő, az együttműködés, a szakértői tudás hozzáférhetősége, az adatok visszakéreshetősége és az ésszerű idő alatt megvizsgálható megoldásváltozatok száma egyaránt fontos lehet. A nyereséget a teljes folyamaton kell értékelni: egy részfeladat gyorsabb végrehajtása akkor jelent valódi előnyt, ha közben nem növeli meg aránytalanul az adat-előkészítést, az utólagos javítás vagy az ellenőrzés terhet.


Ebben az értelemben az AI egyedi segédeszközből fokozatosan a mérnöki munkafolyamat több lépését összekapcsoló eszközzé válhat. Éppen ezért Szabó digitális transzformációval kapcsolatos alapkérdése ma talán még fontosabb, mint a könyv megírásakor: nem önmagában az a kérdés, hogy mit tud az új technológia, hanem hogy hogyan építjük be úgy a mérnöki folyamatba, hogy az eredmények szakmai alapja, ellenőrizhetősége és a felelősség helye közben ne váljon bizonytalaná.

Digitális ikrek: a vizsgálati előzményektől az állapotmodell felé

Szabó a digitális ikret a mérnöki szempontból fontos mennyiségek előrejelzésére szolgáló matematikai modellek együttese felől értelmezi, és az életciklus során gyűjtött, berendezésspecifikus adatokkal történő frissítést is tárgyalja [1: 64-67. o.]. Ebből az állapotfelügyelet számára az a kérdés következik, hogyan kapcsolható a konkrét berendezés mérési története egy olyan modellhez, amely a további viselkedéséről is használható információt ad.

A könyv egyetlen kötetlemmel összefogott lemezek számítási modelljét hozza fel komponensszintű digitális iker példaként, amelyet az alábbi ábra szemléltet. A különböző kötéskialakításokhoz megadott geometria, anyagjellemzők és terhelések meghatározott számítási feladatot írnak le [1: 65-67. o.]. A berendezés egészének részletes virtuális másolata helyett itt egy körülhatárolt szerkezeti kapcsolat viselkedését vizsgáljuk.

A vegyipari környezetre fejlesztett állapotértékelő platformunkban a szétszórta tárolt rajzokat, műszaki adatokat



Kötőelemes lemezekapcsolatok mint a komponensszintű digitális iker példái. A geometria, az anyagjellemzők és a terhelések a modell bemenő adatai [1]

és vizsgálati jelentéseket közös berendezésnyilvántartásba kapcsoltuk össze. A feladat az volt, hogy egy készülék értékeléséhez ne kelljen minden alkalommal külön dokumentumokból újra összeállítani annak előzményeit. Az adatvezérelt karbantartástámogatás megközelítését a SNETP Forum 2026 poszterén is bemutattuk [7]. A felületen az alapadatok mellett a rajzok, a falvastagság-vizsgálatok és az időbeli változások is elérhetők. Ez fontos alap egy későbbi digitális iker számára, de a nyilvántartás és a történeti megjelenítés önmagában még nem előrejelző modell. A továbblépéshez meg kell határozni, milyen károsodási folyamatot írunk le, mely mennyiséget becsüljük, és hogyan vizsgáljuk az előrejelzés alkalmazhatóságát.

A gyors számítási visszacsatolás lehetőségét szemlélteti a Hossain és munkatársai által bemutatott tanított közelítés: egy nyomottvizes reaktor melegági csőkönyökének áramlási jellemzőit számításhoz áramlástanból tanuló neurális operátorral becsülték [8]. Az ilyen közelítés több üzemi állapot gyors vizsgálatát teszi lehetővé. Szabó professzor megkülönböztetése itt is lényeges: a numerikus referencia eredményeinek sikeres közelítése és a fizikai berendezés viselkedésének igazolt előrejelzése nem ugyanaz.

A nehezen hozzáférhető csőhálózati szakaszok felügyeletére kidolgozott fejlesztési koncepciókban a szenzoros állapotkövetést célzott roncsolásmentes vizsgálattal kapcsolnánk össze [6]. Az állapotváltozásra utaló jelzés alapján részletes helyi vizsgálat következne, majd annak eredményét szerkezetintegritási értékelésben használnánk fel. A különböző lépések más kérdést válaszolnak meg: a jelzés változását észlelik, a helyi eltérést jellemzik, illetve annak következményét értékelik. Ezen az úton a felügyelet és a célzott vizsgálat kiegészítheti egymást; az időszakos vizsgálatok általános kiváltása ebből nem következik.

A digitális iker aktualitását ezért nem a berendezés mind tökéletesebb másolatában látjuk. A fontos lehetőség az, hogy a modell és az új vizsgálati tapasztalat a berendezés élettartama során ismételtlen összevethető. Az eltérés indokolhatja a modell felülvizsgálatát, de újabb mérést vagy az üzemeltetési feltételek tisztázását is. A könyv nyílt végű modellfejlesztési szemlélete itt kézzelfogható feladatot jelent: a korrekció után is meg kell vizsgálni, mire alapozható a következő előrejelzés [1: 41-45. és 64-67. o.].

Explainable AI: a magyarázat mire elég?

Amikor az AI már nemcsak adatot dolgoz fel, hanem értékkel, javaslatot tesz vagy egy mérnöki munkafolyamat valamely lépését maga hajtja végre, természetes kérdéssé válik: miért éppen ezt az eredményt kaptuk? Ehhez kapcsolódik a magyarázható mesterséges intelligencia, az explainable artificial intelligence (XAI) fogalma. Szabó Barna az XAI kérdését a numerikus szimuláció megbízhatóságával és auditálhatóságával kapcsolja össze [1: 58-63. o.]. Érvelése szerint az AI integrációja nem teszi kevésbé fontossá a matematikai modellt, a bemenő adatok és az alkalmazási korlátok pontos ismeretét, hanem éppen ellenkezőleg: még inkább kikényszeríti azok tisztázását. A könyv ezt három összekapcsolandó elemmel szemlélteti:



Az XAI-val összekapcsolt numerikus szimuláció három eleme Szabó értelmezésében: ellenőrzött adatok, tudományosan megalapozott algoritmusok és validált előrejelzések [1]

ellenőrzött adatokkal, tudományosan megalapozott algoritmusokkal és validált előrejelzésekkel.

A magyarázhatóság jelentésének pontosításához hasznos támpontot ad az amerikai National Institute of Standards and Technology (NIST) – az Egyesült Államok szabványosítással, mérés-tudománnyal és technológiai módszertannal foglalkozó szövetségi intézete – 2021-ben megjelent Four Principles of Explainable Artificial Intelligence című szakmai jelentése [9]. A dokumentum nem szabvány, hanem olyan módszertani keret, amely négy alapelv segítségével fogalmazza meg, mit várhatunk egy magyarázható AI-rendszer-től. A rendszernek indokot vagy alátámasztást kell adnia az eredményéhez; a magyarázatnak az adott felhasználó számára érthetőnek kell lennie; hűen kell tükröznie azt a folyamatot, ahogyan a rendszer az eredményre jutott; továbbá a rendszernek figyelembe kell vennie saját tudás- és alkalmazási korlátait.

Ez utóbbi megkülönböztetés mérnöki szempontból különösen fontos. A NIST jelentése kifejezetten elválasztja egymástól a magyarázat hűségét (explanation accuracy) és a döntés helyességét (decision accuracy). Egy magyarázat pontosan leírhatja, hogyan jutott el az algoritmus egy eredményhez, miközben maga az eredmény ettől még lehet hibás. Ugyanígy egy helyesnek bizonyuló eredményhez adott, utólag létrehozott magyarázat sem feltétlenül tükrözi megfelelően a modell tényleges működését.

Ez a különbség a saját digitalizációs feladatainkban is jól érzékelhető. A műszaki dokumentumok feldolgozásakor például megőrizhető az eredeti rajz vagy adatlap, valamint nyomon követhető, hogy egy automatikusan kinyert adatot mikor és ki módosított. Ez fontos visszakövethetőséget biztosít: egy értékről ellenőrizhető, hogy honnan származik, és összevethető az eredeti dokumentummal. Mindez azonban még nem magyarázza meg, hogy a tanított felismerési modell miért éppen azt a karaktert, számot vagy táblázati struktúrát ismerte fel.

A kétféle információ tehát más célt szolgál. A visszakövethetőség azt mutatja meg, honnan származik az eredmény és mi történt vele a feldolgozás során; a magyarázhatóság pedig azt próbálja feltárni, milyen tényezők alapján jutott a modell az adott eredményhez. Egy mérnöki rendszerben mindkettő fontos lehet, de egyik sem helyettesíti a másikat.

Ugyanezért a magyarázhatóság, a verifikáció és a validáció sem azonos fogalmak. A magyarázhatóság arra kérdez rá, hogy milyen értelmezhető és a rendszer működését megfelelően tükröző információ adható az AI döntéséről. A numerikus megoldás verifikációja azt vizsgálja, hogy a matematikai probléma közelítő megoldását megfelelő pontossággal számítottuk-e ki. A validáció pedig arra vonatkozik, hogy a matematikai modell a meghatározott felhasználási cél szempontjából megfelelően reprezentálja-e a vizsgált fizikai jelenséget. A bizonytalanság számszerűsítése ehhez azt teszi hozzá, hogy

mennyire bizonytalan a döntéshez felhasznált előrejelzés [1:52-63. o.] [9, 10]. A NASA modellezési és szimulációs szabványa szintén elkülönített, életcikluson át kezelt követelményként foglalkozik a modellek hitelességének, verifikációjának, validációjának és bizonytalanságának kérdéseivel.

Ebből gyakorlati szempontból az következik, hogy nem minden magyarázat hasznos pusztán attól, hogy létezik. Egy szakértő számára annak van értéke, ha a kapott információ segít eldönteni, mely bemenő adatot, feltételezést vagy modellkomponenst érdemes felülvizsgálni, milyen körülmények között válhat bizonytalanra az eredmény, illetve szükség van-e további mérésre vagy vizsgálatra. Más típusú magyarázat lehet megfelelő egy fejlesztőnek, egy anyagvizsgálónak, egy üzemeltetőnek vagy egy jóváhagyásért felelős mérnöknek; maga a NIST megközelítése is hangsúlyozza, hogy a magyarázatnak az adott felhasználó számára kell értelmezhetőnek lennie.

A szakértői jóváhagyás ezért csak akkor jelent valódi kontrollt, ha a szakember rendelkezik azokkal az információkkal, amelyek alapján az AI eredményét érdemben meg is tudja kérdőjelezni. Egy „elfogadom” gomb önmagában még nem emberi felügyelet. Tudni kell, milyen adatokra támaszkodott a rendszer, milyen feltételezések és korlátok mellett működik, mekkora bizonytalanság kapcsolódik az eredményhez, és mely esetekben kell más módszerhez vagy további vizsgálathoz fordulni.

Ebben az értelemben az XAI jelentősége a mérnöki gyakorlat számára nem abban áll, hogy az AI minden döntéséhez közérthető történetet gyárt. A fontosabb cél az, hogy az AI-val támogatott mérnöki folyamatban látható maradjon, mire alapozzuk az eredményt, hol vannak annak alkalmazási korlátai, és milyen információ alapján vállalhat érte felelősséget a szakember. Ez a kérdés közvetlenül visszavezet Szabó könyvének egyik alap gondolatához: nem elegendő eredményt előállítani – azt is igazolni kell, hogy milyen alapon használjuk fel.


A korábbi vizsgálati adatok újrafelhasználása

Az anyagvizsgálat régóta az anyagmodellek kialakításának és paraméter-azonosításának alapja. A kísérleti anyagjellemzés megelőzi és megalapozza a modell mérnöki alkalmazását; az újabb vizsgálatok a modell pontosítását és alkalmazási határainak feltárását is szolgálják [1:41-45. o.]. Az AI-val támogatott feldolgozás ennek a már meglévő kapcsolatnak az információk háttérét bővítheti. Saját munkáinkban a kérdés az, hogyan használhatók fel együtt a különböző időpontokban, eltérő formában rögzített mérési és műszaki információk.

A karbantartástámogató fejlesztés egyik konkrét feladata a hőcserélők csőkötegein végzett vizsgálatok csőenkénti történetének összeállítása volt. Az adatokat különböző vizsgálatok, eltérő években és eljárásokkal készült jelentéseiből kellett összerendezni. Erre egy időpontok között léptethető csőkötegtérképet és a kiválasztott cső adatait megjelenítő értékelő modul alakítottunk ki. A felhasználó az adott csőhöz visszakeresheti az évet, a közölt falvastagságcsökkenést, a vizsgálatot és az alkalmazott technikát.

Az alábbi ábra a térképes megjelenítést mutatja: a falvastagságcsökkenés és az eltömődés kategóriái mellett külön jelölést kapnak a nem vizsgált, a regisztrálási érték alatti jelet adó és a ledugózott csövek. Így az állapotváltozás mellett a vizsgálati lefedettség is áttekinthető.

A közös színskála áttekinthetőbbé teszi az adatokat, de nem helyettesíti az eltérő vizsgálati eljárásokból származó eredmények szakmai összevetését. Az értékeléshez meg



Hőcserélő-csőköteg vizsgálati térképe és időcsúszkája. A színek és jelölések a vizsgálati eredményeket, illetve azok hiányát különböztetik meg; a kiválasztott csőhöz a vizsgálati előzmények is visszakereshetők [6]

kell tartani az eredeti módszert, a vonatkoztatási alapot és a rendelkezésre álló bizonytalansági információt is. Ahol csak kategória vagy tartomány áll rendelkezésre, abból a feldolgozás nem hoz létre pontosabb mérést. Ez azért fontos, mert a megjelenítés egységesítése és a mérési eredmények összehasonlíthatóságának igazolása két külön feladat.

A bemutatott értékelő modul előre meghatározott, az üzemi karbantartási gyakorlathoz igazítható szabályokból állít elő ajánlásokat [6]. Ez szabályalapú döntéstámogatás; az AI-alapú élettartam-előrejelzés külön modellfejlesztést és igazolást igényel. A tapasztalat a könyv egyik alap gondolatát erősíti: előbb a felhasználás célját és az ahhoz szükséges információt kell meghatározni, s csak azután az alkalmazásra választott eszközt. Egy adatplatform értéke nem attól függ, mennyi AI-t építünk bele, hanem attól, milyen mérnöki kérdés megválaszolását teszi lehetővé.

A gyakorlati nyereség elsőként abban vizsgálható, hogy a mérnök mennyi munkával tudja összeállítani egy cső vagy berendezés vizsgálati történetét, és mennyi idő marad az eltérések értelmezésére. Külön érdemes mérni az adatkeresést, az összerendelést, az ellenőrzést és a javítás munkaráfordítását. Az AI haszna itt nem az anyagvizsgálati következtetés lecserélése, hanem az értelmezéshez szükséges információ előkészítésének támogatása.

A modellek gondozása szervezeti feladat

A könyv a simulation governance, vagyis a szimulációs irányítás fogalmával foglalja össze a vezetés feladatát a számított információ megbízhatóságának biztosításában.

A modellfejlesztést nyílt végű tevékenységnek tekinti: új adatok és új módszerek indokolhatják a korábbi megoldás felülvizsgálatát [1: 15-18. és 36-45. o.]. Az AI-val támogatott folyamatok ezt a kérdést tovább szélesítik. Már nem csak egy számítási modell, hanem adatbázisok, tanított modellek és egymásra épülő szoftverlépések kapcsolatát kell gondozni.

Egy tanított modell új változatánál is a felhasználási feladathoz kell visszatérni. A bővebb tanítóanyag vagy az új algoritmus nem teszi fölöslegessé annak vizsgálatát, hogyan változik a teljesítmény a fontos esetszortokon. A korábbi értékelések megismételhetőségéhez a használt modell-, adat- és eljárásváltozatot is azonosítani kell. A modell gondozása így nem egyszeri informatikai bevezetés, hanem a mérnöki módszer fenntartásának része.

A modellek életciklusára kiterjedő fejlesztést, használatot és értékelést a NASA-STD-7009B módszertani kerete is nevesíti [10]. A könyvből a saját gyakorlatunk számára azt emeljük ki, hogy a feladatot és az elvárt alátámasztást nem helyettesíti egy szoftver előírása. A bevezetés céljai között a hasznosulást is érdemes megfogalmazni: több megoldásváltozat értékelését, a gyengén ismert paraméterek tisztázását vagy az ismétlődő adat-előkészítés csökkentését. Az előrejelzési pontosság és a teljes munkaráfordítás együtt mutatja meg, mit nyertünk az új megoldással.

Az együttműködés egyik feltétele a szakterületek közötti közös nyelv. Egy „validált” adatbázis, egy ellenőrzött szoftver és egy adott célra validált modell nem ugyanaz az állítás. Ha az anyagvizsgáló, az adatkutató és az üzemeltető ezt eltérően érti, egy technikailag összekapcsolt rendszerben is elveszhet a lényeges információ. A könyv terminológiai figyelmeztetése így nagyon gyakorlati kérdéssé válik: az átadott eredmény mellett annak jelentése és alkalmazási korlátja is közös legyen [1: 9-12. o.].

Miért aktuális tehát ez a könyv?

Szabó Barna Bridging the Gap írása azért aktuális, mert a könyvben vizsgált különbség az eszköz működése és az eredmény indokolt felhasználása között az AI-val támogatott mérnöki munkában is újra megjelenik. A képfelismerés, a dokumentumfeldolgozás, a javasolt anyagszerkezet és a gyors előrejelzés más-más feladat, de mindegyiknél meg kell mutatni, hogyan kapcsolódik a gépi eredmény a vizsgált fizikai problémához. A korábbi radiográfiai munkánk és a jelenlegi állapotértékelési fejlesztések azért fontosak számunkra, mert ezt a kérdést saját feladatainkon keresztül is meg tudjuk fogalmazni.

Szabó professzor könyvének mai értékét abban látjuk, hogy nem az algoritmus megválasztásával kezdi az érvelést. Azt kérdezi, mit akarunk megtudni, milyen feltételezésekkel dolgozunk, és milyen alapunk van az eredmény felhasználására. Ebből kiindulva az AI lehetőségeit sem csak gyorsításként vagy kockázatként érdemes szemlélteni. Az érdemi előrelépés az lehet, ha több hasznos kérdést tudunk feltenni, több megoldást tudunk megvizsgálni, és az új tapasztalatból következetesebben tudunk tanulni.

A mérés, a modellalkotás és a mérnöki ítélet eddig is

összetartozott. Most annak a lehetősége nyílik meg, hogy a közöttük lévő információátadás és a megoldáskeresés nagyobb része váljon automatizálttá. Az AI így egyedi segédeszközből a mérnöki munkafolyamat több lépését összekapcsoló környezetté válhat. Ez a munkaszervezést és a mérnöki tudás alkalmazásának módját is átformálhatja. A feladatunk az, hogy ebben az új munkamegosztásban is látható maradjon, mit tudunk, mit becsülünk, és mit kell még vizsgálnunk. Erre a változásra ad a könyv ma is használható kiindulópontot.

A következő részben innen folytatjuk a „Mit jelent mérnöknek lenni?” kérdésével: hogyan alakul a mérnök feladata és felelőssége ebben az új munkamegosztásban?

Dudra Judit, PhD, vezető mérnök

Szávai Szabolcs, PhD, divízió vezető

AEMI Atomenergia Mérnökiroda Kft., Mérnöki Divízió

Felhasznált irodalom

- [1] Szabó Barna: Bridging the Gap: Advancing Finite Element Analysis in Numerical Simulation. PaperTrue Ltd., 2025. ISBN 979-8-9934924-0-7.
- [2] Dudra Judit, Szávai Szabolcs: Könyvismertetés: Dr. Szabó Barna: Bridging the Gap. Anyagvizsgálók Lapja, 2025/IV. lapszám., 37-38.
- [3] Dudra Judit, Zsíros Zsombor, Margitai Péter, Pataki Márton, Szávai Szabolcs, Matók Viktor, Balogh Csilla, Viczena Julianna, Béres Bence: Mesterséges Intelligencia alkalmazása a képalkotó vizsgálatok értékelésében. Anyagvizsgálók Lapja, 2023/4. lapszám, 23-28. MTMT: 36438300.
- [4] Zeni C., Pinsler R., Zünger D. és mtsai.: A generative model for inorganic materials design. Nature, 639, 624-632, 2025. DOI: 10.1038/s41586-025-08628-5.
- [5] Hufnagel T. C., Addepalli P., Bhattacharjee A. és mtsai.: AIMD-L: An automated laboratory for high-throughput characterization of structural materials for extreme environments. Preprint, arXiv:2603.06835v1, 2026. március 6. DOI: 10.48550/arXiv.2603.06835.
- [6] Szávai Szabolcs: Újdonságok a roncsolásmentes anyagvizsgálat területén. In: 45. Balatoni Ankét konferenciakiadvány. Siófok, 2025. november 27-29.
- [7] Szávai Szabolcs, Dudra Judit: Data driven support of maintenance activities (poster presentation). SNETP Forum 2026, Madrid, Spain, 25-27 March 2026.
- [8] Hossain R., Ahmed F., Kobayahi K., Koric S., Abueidda D., Alam S. B.: Virtual sensing-enabled digital twin framework for real-time monitoring of nuclear systems leveraging deep neural operators. npj Materials Degradation, 9, 21, 2025. DOI: 10.1038/s41529-025-00557-y.
- [9] Phillips P. J., Hahn C. A., Fontana P. C., Yates A. N., Greene K. K., Broniatowski D. A., Przybocki M. A.: Four Principles of Explainable Artificial Intelligence. NISTIR 8312, 2021. DOI: 10.6028/NIST.IR.8312.
- [10] NASA: Standard for Models and Simulations. NASA-STD-7009B, 2024. március 5.
- [11] SIEMENS AG: Siemens launches the Eigen Engineering Agent, bringing purpose-built AI to industrial automation engineering. Sajtóközlemény, 2026. április 20.
- [12] SIEMENS AG: Siemens takes AI for the physical world to the next level with two new Eigen Engineering Agent capabilities. Sajtóközlemény, 2026. június 17.