

VASBETON HIDAK INTELLIGENS MONITORINGJA DIGITÁLIS IKER ÉS MESTERSÉGES INTELLIGENCIA ALKALMAZÁSOK HASZNÁLATÁVAL



Asseel Al-Hijazeen – Koris Kálmán

<https://doi.org/10.32969/VB.2024.4.2>

A vasbeton hidak biztonsága és fenntarthatósága jelentősen növelhető a szerkezet működés közbeni állapotának folyamatos monitoringjával és ennek révén a különböző terhelési körülmények között várható viselkedésük és állapotuk pontosabb előrejelzésével. A monitoring rendszer által mért adatok alapján, digitális iker (DI) és mesterséges intelligencia (MI) alapú eszközök használatával a szerkezet statikai állapota valós időben követhető, és a megfelelő határértékek definiálása mellett automatikus hibajelzés kapható nem megfelelő állapot esetén. A potenciális tartószerkezeti problémák korai felismerésével a későbbi, komolyabb károsodások megelőzhetők, még azok bekövetkezése előtt. Annak ellenére, hogy több hazai hídon jelenleg is van monitoring rendszer, a mért adatok nyers formában gyakran feldolgozatlanok maradnak, így a híd állapota pusztán ezek alapján kevésbé becsülhető meg. A célunk az volt, hogy a mért nyers monitoring adatokat digitális iker és mesterséges intelligencia alapú eszközök alkalmazásával, valós időben feldolgozzuk, és a híd statikai állapotának jellemzésére alkalmas adatokká alakítsuk, ilyen módon lehetővé téve a szerkezettel kapcsolatos, potenciális problémák időben történő felismerését. A kifejlesztett eljárás alapjait egy meglévő, magyarországi vasbeton szekrény keresztmetszetű közúti híd példáján keresztül mutatjuk be. A választott híd felszerkezet statikai viselkedésének numerikus szimulációjához és a megfelelőségi feltételek ellenőrzéséhez a digitális iker (DI) technológiát alkalmaztuk. Az igénybevételek és alakváltozások meghatározását, valamint a teherbírási (ULS) és használhatósági (SLS) feltételek ellenőrzését egy validált 3D-s végeselemes modellen (VEM) végeztük el. Monte Carlo-szimulációval különböző forgalmi terheket generáltunk, és minden egyes teherelrendezés esetén meghatároztuk a híd kihasználtságát különböző ULS és SLS határállapotokban, különös tekintettel a feszültségekre, a lehajlásra és a repedéstágasságra. A numerikus modellben a tényleges hídon elhelyezett szenzoroknak megfelelő helyeken az adott szenzor által mérhető fizikai jellemzőket (pl. nyúlások) is rögzítettük minden egyes futtatás során. Ilyen módon két adathalmazt kaptunk, amelyek közül az egyik a virtuális híd statikai állapotát (kihasználtságok ULS és SLS állapotokban), a másik a – valós hídon lévő szenzoroknak megfelelő – virtuális monitoring pontokban egyidejűleg “mérhető” mennyiségeket tartalmazta. A két adathalmaz közötti kapcsolatot mesterséges intelligencia (MI) alkalmazás, azon belül a mesterséges neurális hálózatok (ANN) segítségével határoztuk meg. Ezen meghatározott összefüggés alapján a tényleges hídon mért monitoring adatok valós időben feldolgozhatók és meghatározhatók a híd statikai állapotára (ULS és SLS kihasználtságok) vonatkozó számszerű információk, ezzel segítve a szerkezet állapotának megítélését, valamint az állapottal és a karbantartási igényekkel kapcsolatos előrejelzések készítését.

KULCSSZAVAK: híd, monitoring, neurális hálózat, digitális iker, kárfelismerés, mesterséges intelligencia

1. BEVEZETÉS

Bár az európai úthálózat hídjainak jelentős része az elmúlt 50 évben épült, néhány közülük jóval régebbi. Ez az előregedő infrastruktúra napjainkban kritikus kihívással néz szembe: a közúti forgalom egyre növekvő mértékével és súlyával. A hidakra nehezedő terhek jóval meghaladják azt, amire eredetileg tervezték őket. A BRIME jelentés (Woodward és társai, 2001)

ráadásul komoly hiányosságokat tárt fel az autópályahidakon Európa szerte. Franciaországban, Németországban és az Egyesült Királyságban kiemelkedően magas volt a valamilyen módon sérült vagy károsodott hidak aránya: 39%, 30%, illetve 37%. Ezek a problémák vasbeton hidak esetén különböző okokra vezethetők vissza, amelyek öt alapvető kategóriába sorolhatók. Az első a korrózió, amely a betonacélokat és a feszítőbetéteket egyaránt károsítja. A betonban megjelenő

repedések fő okai a zsugorodás, a fagyási-olvasadási ciklusok, az alkáli-szilikát reakció és az ütések okozta sérülések. A károk kialakulásában a tervezési és kivitelezési hibák is szerepet játszanak, beleértve a nem megfelelő betonozást, tömörítést, a vízszigetelési és a hőtechnikai tervezési hibákat. Emellett a szerkezet túlterhelése, a hibás saruk, dilatációs hézagok és vízelvezető rendszerek is gyakran hozzájárulhatnak a tartószerkezet károsodásához. Nem utolsó sorban olyan külső tényezők, mint a tűz, az árvíz és a járművek ütközése a normál működésen túlmenően is veszélyt jelentenek.

A felsorolt problémákra való tekintettel a meglévő és új hidak folyamatos monitoringja egyre fontosabbá válik. Az intelligens monitoring rendszerek (Smart Health Monitoring, SHM) rendszerek valós idejű adatokat szolgáltatnak hídszerkezet állapotával kapcsolatban, lehetővé téve ezzel a proaktív hídfenntartást. A szerkezeti viselkedés ok-okozati összefüggéseinek megértésével, a várható állagromlás modellezése mellett, lehetővé válik a mérnökök számára, hogy felismerjék és kezeljék a tartószerkezeti problémákat, mielőtt azok súlyossá válnának, ezáltal csökkentve a fenntartási költségeket a teljes életciklus alatt (Huang és társai, 2010). Az olyan hagyományos diagnosztikai módszerek, mint például a vizuális ellenőrzés vagy a roncsolásmentes vizsgálat (ultrahang, röntgen, akusztikus emisszió stb.) általában alkalmasak a nagyobb károsodások helyének, mértékének megállapítására, a kisebb, nehezen észlelhető, de a szerkezet viselkedését mégis befolyásoló károsodások viszont ezek mellett észrevétlenek maradhatnak. A lokalizált vizsgálatok fontosak lehetnek a kisebb repedések, betonfedés leválások és hasonló károsodások észleléséhez, mielőtt azok kritikussá válnának (Gharehbaghi és társai, 2022). Ezek a módszerek azonban inkább a kisebb, egyszerűbb szerkezeteknél alkalmazhatók megbízhatóan, mivel részletes kiindulási adatokat igényelnek, és szükség van a sérült területek helyének pontos ismeretére, így alkalmazásuk nagy és komplex szerkezeteknél nem hatékony, drága és időigényes lehet (Shih és társai, 2009; Chang és társai, 2003).


Housner és társai (1997) az intelligens szerkezeti monitoringot a szerkezeti károsodások felismerésére szolgáló érzékelési technikákat és a tartószerkezeti jellemzők átfogó elemzését magában foglaló módszerként határozták meg. A számos nagyfrekvenciás érzékelővel felszerelt monitoring rendszerek a tartószerkezet hosszú távú megfigyelése során hatalmas mennyiségű adatot képesek összegyűjteni, és az SHM egyik kulcsfontosságú területe ezen adatok elemzése és értelmezése a szerkezet állapotának megismerése céljából.

A hidak monitoringja jellemzően modellalapú módon vagy adatvezérelt módon történhet (Sun és társai, 2020). A modellalapú módszerek a híd részletes végeselemes modelljét hozzák létre, amelynek paramétereit folyamatosan frissítik a szenoradatok felhasználásával. A numerikus modell előrejelzései és az új fizikai mérések közötti jelentős eltérések potenciális károsodásra utalhatnak. Az adatvezérelt módszerek ezzel szemben megkerülik a fizikai modellt, és közvetlenül az érzékelő adatokat elemzik statisztikailag a szerkezeti változásokhoz kapcsolódó minták azonosítása érdekében. A modellalapú módszerek egyértelmű fizikai értelmezést kínálnak, így ezek előzetes ismereteket igényelnek. Az adatvezérelt módszerek alkalmazkodóképesebbek, de kevesebb betekintést nyújtanak a károsodás konkrét okába. Mindkét megközelítésnek vannak előnyei, és az átfogóbb szerkezeti elemzés érdekében a két módszer kombináltan is alkalmazható.

2. A DIGITÁLIS IKER ÉS A GÉPI TANULÁS TECHNOLÓGIÁK ÖSSZEKAPCSOLÁSA AZ INTELLIGENS MONITORING SORÁN

A hidak állapotának ellenőrzési folyamata napjainkban jelentős átalakuláson megy keresztül, amelyet a digitális iker (DI) technológia és a gépi tanulási (Machine Learning, ML)

1. ábra: A digitális iker és a mesterséges intelligencia összekapcsolása hidak intelligens monitoringjához



algoritmusok erőteljes kombinációja hajt. A DI technológia révén létrehozhatjuk a híd digitális másolatát, amiben vizuális, illetve számszerű formában rögzíthetők a vizsgálat szempontjából fontos adatok, mint például a geometriai- és anyagjellemzők, a szerkezeti viselkedés és az esetleges károsodások. A híd ezen digitális reprezentációja lehetővé teszi a híd aktuális állapotának egyértelmű megjelenítését. A gépi tanulás módszerével ugyanakkor lehetőségünk van elemezni a valós szerkezeten mért érzékelési adatokat (pl. nyúlások, elmozdulások, feszültségek stb.), ezáltal pontosabb képet kaphatunk a szerkezet viselkedéséről, aktuális állapotáról, várható élettartamáról, és az esetleges tartószerkezeti károsodások kialakulásáról.

A DI és az ML technológiák fúziója egyelőre kezdeti stádiumban van (Liu és társai, 2020), de izgalmas új lehetőségeket kínál a hidak intelligens monitoringja terén. A gépi tanulásnak a DI modellbe való integrálásával „szinkron működést” hozunk létre a fizikai híd és annak digitális ikertestvére között. A valós szerkezeten mért szenzoradatok lesznek a rendszer kulcsfontosságú elemei, amelyek alapján a DI modell felépíthető és kalibrálható (1. ábra). A DI ilyen módon történő folyamatos felügyelete és a mért adatok elemzése lehetővé teszi a lehetséges szerkezeti problémák korai felismerését.

3. MÓDSZERTAN

Kutatásunk során a fentiekben említett, korszerű DI és ML technológiák segítségével egy eljárást dolgoztunk ki, amellyel a vasbeton közúti hidakon mért monitoring adatok és a tartószerkezet állapotát jellemző számszerű paraméterek (kihasználtság különböző ULS és SLS határállapotokban) közötti összefüggés meghatározható. Az eljárás három fő elemet integrál, melyeket az alábbiakban ismertetünk.


VEM modell fejlesztése és használata: Egy meglévő, utófeszített, szekrényes keresztmetszetű, vasbeton közúti híd felszerkezetének részletes 3D-s végelem-modellje (VEM) szolgált digitális ikertestvérként. A numerikus modell geometriai- és anyagjellemzőit az eredeti kiviteli és megvalósulási tervek,

továbbá a saját helyszíni szemrevételezéses vizsgálataink és roncsolásmentes betonszilárdság méréseink alapján vettük fel. Az Eurocode szabványrendszer figyelembevételével elvégeztük a híd erőtani ellenőrzését, e mellett, végrehajtottuk a modell verifikációját és validálását is, ami a tényleges hídon végzett próbaterhelés eredményei alapján készült. Az eredmények alapján a modellben számított alakváltozások, feszültségek és repedéstágasságok megfelelő pontossággal tükrözték a valós szerkezet viselkedését. A numerikus modell felhasználásával Monte-Carlo szimulációt végeztünk, mely során véletlenszerűen generált forgalmi terhek esetére meghatároztuk a szerkezet igénybevételeit, alakváltozását és repedéstágasságait. Ezek mellett, minden futtatás során rögzítettük a tényleges hídon elhelyezett szenzoroknak megfelelő virtuális monitoring pontokban az adott érzékelő típusának megfelelő, számított fizikai jellemzőket (pl. nyúlásmérő bélyeg esetén a modell adott pontjában számolt megnyúlást).

Szenzorhálózat felügyelete: A fizikai hídon már eleve meglévő, illetve általunk elhelyezett új szenzorok hálózata valós idejű adatokat (vízszintes és függőleges nyúlások, hőmérséklet, támaszmozgás) rögzített több mint 1 éven keresztül. Ezek a mérések szolgáltatták a bemeneti adatokat tényleges a híd szerkezeti válaszáának későbbi értékeléséhez.

Gépi tanulás integrációja: Egy mesterséges neurális hálózatot (ANN) fejlesztettünk ki a digitális ikerből származó adatok feldolgozására. Ennek segítségével kapcsolatot tudunk teremteni a szerkezet erőtani állapota (jellemzően valamely ULS vagy SLS állapotra vonatkozó kihasználtság), és a virtuális monitoring pontokban számított fizikai jellemzők között. Ez alapján, az ANN rendszer – kellő számú futtatás segítségével történő – betanítása után a képesek voltunk megjósolni a valós szerkezet állapotát a hídon lévő szenzorok adataira alkalmazva a digitális iker elemzésével kapott összefüggéseket. A fejlett numerikus szimuláció és a gépi tanulási módszer ilyen módon összekapcsolható volt a valós hídon mért monitoring adatokkal, amely segítségével a híd statikai állapota akár valós időben is elvégezhető.

2. ábra: A Soroksári híd hossz- és keresztmetszete





3. ábra: Hosszirányú elmozdulás mérése a 13 támasznál (A), a 15 támasznál (B) és hőmérsékletmérő a 14 támasznál (C)

A módszer segítségével a híd infrastruktúra állapota valós időben nyomon követhető, szükség esetén, a rendszer jelzései alapján a híd részletesebb diagnosztikája, karbantartása, javítása vagy megerősítése elvégezhető, megelőzve a komolyabb károsodás, vagy veszélyhelyzet kialakulását, elősegítve ezzel a biztonságosabb és hatékonyabb fenntartást.

4. ESETTANULMÁNY

4.1. A vizsgált híd leírása

A fentiekben vázolt módszert egy esettanulmányon keresztül mutatjuk be. A vizsgált híd az M0 autópálya Soroksári Duna-ág hídjának régebbi, 1990-ben épült bal-pálya hídjára (2. ábra). A híd felszerkezet digitális ikertestvérét az *AxisVM* végeselemes szoftver segítségével készítettük el. A hídon 2020-ban 8 db hőmérsékletmérőből és 10 db hosszirányú alakváltozásmérő eszközökből álló monitoring rendszert telepítettek, a szerkezet különböző keresztmetszeteiben. A kutatási munka során, a híd felszerkezetének viselkedésére vonatkozó átfogóbb adatok megszerzése érdekében a Magyar Közút Zrt. mint hídüzemeltető és a Budapesti Műszaki és Gazdaságtudományi Egyetem Építőmérnöki Karának Szerkezetvizsgáló Laboratóriuma segítségével további hét nyúlásmérő műszert is telepítettünk a szekrénykeresztmetszet belsejébe.

A mederhíd felszerkezet 3 nyílású folytatólagos feszített vasbeton gerendahíd. A főtartó a támaszok felett kiékelte, két külön cellából álló, változó magasságú szekrénykeresztmetszet, integrált oldalsó konzolos járdalemezekkel. A híd a támaszok felől konzolos szabad szereléssel épült. A híd teljes keresztmetszeti szélessége 20,64 méter, a vizsgált szakasz pedig összesen 147,3 méter hosszú (2. ábra).


A korábbi hídsaru javítások során telepített, már meglévő monitoring rendszer folyamatosan méri a híd állapotát. A rendszer Rhodium 30305 Pt100 típusú hőmérsékletmérőket és ASM PCQA24 mágnesszabályozós távolságmérőket használ a hőmérséklet és a hosszirányú alakváltozások mérésére. Ezeket az érzékelőket a híd hossz tengelye mentén minden támasznál elhelyezték. A pillérek geometriája a méretkülönbségek miatt kisebb eltéréseket mutat, a szenzorok elrendezése ennek ellenére következetes. A távolságmérő szenzorok nem mozgatható felét egy hajlított, rozsdamentes acélból készült konzol segítségével rögzítették minden egyes pillér felső végéhez, míg a hajtóműfej egy csuklós rúddal csatlakozik a kerethez. A mérőrendszer pontossága 0,1 mm, a mintavételi frekvencia 5 Hz. A hőmérsékletmérők mérési tartománya -30 °C és +85 °C között van, a Pt100 érzékelők „A” pontossági osztályúak, a mérés pontossága így 0,1 °C, a mintavételi frekvencia pedig 1 Hz. A szenzorok védőcsőben vezetett kábelekkal

vannak összekötve a híd központi mérőegységével, elkerülve az ideiglenes emelési pontokat és más fontos szerkezeti tartóelemeket. A szenzorok jelei a központi mérőegységben található HBM PMX PX455 mérőkártyákhoz csatlakoznak. A hőmérsékletmérő és elmozdulásmérő szenzorok jelei között a szinkronitás biztosított. A szekrénykeresztmetszet belsejében, a 13, 14 és 15 támaszoknál elhelyezett néhány szenzor fotója a 3. ábrán látható. A biztonság és hatékonyság érdekében a telepített szenzorhálózat autonóm állapotfigyelést tesz lehetővé, ami kiküszöböli a hídon végzett folyamatos kézi beállítások szükségességét. Az érzékelők adatai biztonságos Ethernet-kapcsolaton keresztül, közvetlenül egy erre a célra szolgáló, HPE EL300-as ipari vezérlő számítógépre kerülnek továbbításra, a gépen szabványos MS Windows 10 Professional operációs rendszert fut. Az adatgyűjtést a HBM CatmanEasy szoftvere kezeli, biztosítva az érzékelők leolvasásainak hatékony és megbízható gyűjtését és továbbítását.

A szóban forgó híd jelenlegi állapota tartószerkezeti szempontból megfelelőnek tekinthető, ugyanakkor a jövőben várható, természetes állagromlásra való érzékenysége miatt szükséges a további, folyamatos monitoring. A meglévő felügyeleti rendszer továbbfejlesztése érdekében javasoltuk, hogy a hídra kiegészítő szenzorokat építsenek be, ennek eredményeképpen 2022 decemberében hét darab új nyúlásmérő bélyeg felszerelésére került sor, a szekrényes keresztmetszet belsejében. A meglévő, illetve az utólag felszerelt kiegészítő szenzorok adatai szolgálták a következőkben ismertetett intelligens monitoring rendszer alapjául. A már meglévő, és az általunk telepített szenzorok hídon való elhelyezkedését a 4. ábra szemlélteti.

4.2. Digitális Iker alkalmazása SHM céljából

A digitális iker koncepcióját, mint a hidak monitoringjának egy hatékony eszközét Grieves vezette be 2002-ben (Grieves, 2014). A DI technológia három fő összetevője: a) a valós fizikai híd, b) a híd virtuális másolata a digitális térben, és c) folyamatos, szinkronizált adatáramlás a valós és a virtuális híd között (Grieves, 2014). Más iparágakhoz hasonlóan a digitális iker alkalmazása egyre nagyobb teret nyer napjainkban a hídfenntartás és üzemeltetés terén. A fizikai híd szenzoradataival folyamatosan frissített virtuális modell létrehozásával a mérnökök proaktív felügyeletet és karbantartást tudnak megvalósítani, amely segítségével a potenciális problémák időben azonosíthatók és kezelhetők (Pregolato és társai, 2023). A digitális iker lényegében a híd virtuális megfelelőjeként működik, lehetővé téve a modell valós idejű frissítését, a valós szerkezetre vonatkozó visszajelzéseket, sőt a kockázatok felmérésére és a teljesítmény



4. ábra: A már meglévő hőmérséklet- és hosszirányú elmozdulásmérő szenzorok, és az újonnan telepített nyúlásmérő bélyegek pozíciója a hídon


előrejelzésére szolgáló szimulációkat is (Ladj és társai, 2020). Ez a digitális másolat túlmutat a híd egyszerű tükrözésén, olyan algoritmusokat tartalmaz, amelyek elemzik a valós hídon rögzített szenzor adatokat, és akár a hídkarbantartó rendszeren belül is képesek önállóan műveleteket végezni. A kulcs a megfelelő digitális modell létrehozásában rejlik, amely kellő pontossággal tükrözi a tényleges híd viselkedését (Roszevák, Haris, 2021). A Ye és társai által a staffordshirei vasúti hidakon végzett tanulmány is bizonyítja ezen megközelítés hatékonyságát (Ye és társai, 2019). Kutatásuk rávilágít a különböző adatforrások kombinálásának és többféle numerikus modell egyetlen digitális ikerbe történő integrálásának fontosságára a megbízhatóbb előrejelzések érdekében. Az általuk javasolt digitális iker modell hatékonyságának értékeléséhez és a híd egészségi állapotának nyomon követésére a kutatás nyolc alapvető képességet határoz meg a szakirodalom alapján (Ye és társai, 2019).

A Soroksári híd intelligens monitoringjához fejlesztett digitális iker készítésekor tekintettel voltunk a Ye és társai (2019) által megfogalmazott nyolc alapvető képességre, melyek közül néhányat a következőkben sorolunk fel. A vizualizáció érdekében a híd digitális modelljét az AxisVM szoftver segítségével hoztuk létre. A modell tartalmazta eredeti kiviteli és megvalósulási terveken szereplő geometriai adatokat, anyagjellemzőket és feszítési paramétereket, továbbá a saját helyszíni szemrevételezéses vizsgálataink és roncsolásmentes betonszilárdság méréseink alapján rögzített információkat a

geometria, anyagjellemzők és meglévő károsodások kapcsán. A numerikus modellt annak verifikálásával és – a BME által 1990-ben végzett próbaterhelés eredményei alapján történő – validálásával pontosítottuk (lásd 4.3. fejezet). Új nyúlásmérő szenzorok beépítésével kibővítettük a monitoring rendszert, hogy a nagyobb számú rendelkezésre álló információ alapján pontosabban becsülhető legyen a tartószerkezet állapota. A digitális iker felhasználásával különböző terhelési eseteket szimuláltunk, a kapott eredményeket és adatokat pedig részletesen elemeztük és feldolgoztuk az integrált neurális hálózat nyújtotta gépi tanulási eszközök kihasználásával. Ilyen módon meg tudtuk határozni az összefüggést a tartószerkezet állapotát leíró számszerű változók (pl. kihasználtságok) és a hozzá tartozó, a valós szerkezeten lévő szenzoroknak megfelelő pontokban számított fizikai jellemzők (pl. nyúlások) között. Ezen összefüggés ismeretében a valós hídon mért szenzor adatok valós időben is feldolgozhatók, és a szerkezet állapota értékelhető. Az alkalmazott neurális hálózat képes arra, hogy a szimulációk számának növelésével tanuljon és fejlődjön, a valós hídról gyűjtött új adatok alapján pedig a digitális iker modell is fejleszthető, pontosítható.

4.3. A végeelemes modell

A Soroksári híd digitális ikertestvérének létrehozása során az első lépés az 5. ábrán látható 3D-s végeelemes modell elkészítése volt, az AxisVM szoftverben. A modell vasbeton anyagú héjelemekből, támaszokból és utófeszítő



5. ábra: A Soroksári híd végeleemes modellje: A) utófesztítő kábelek a szekrénykeresztmetszet gerincében; B) a modell renderelt nézete; C) koncentrált terhek a pályalemezen; D) lehajlott hidalak a statikai számítás után

kábelekből áll. A modell geometriáját a híd kiviteli tervei alapján alakítottuk ki, a beton anyagminőségét a terveken megadott C30/37 értékre vettük fel, amit az általunk végzett roncsolásmentes betonszilárdság vizsgálatok is megerősítettek. A híd pályalemezébe és a szekrénykeresztmetszetekbe épített utófesztítő kábeleket a terveknek megfelelő pozíció, alak és feszítési feszültségek figyelembevételével építettük be a modellbe, *Axis VM* feszítőerő opciójának használatával.


A megfelelő pontosságú analízis érdekében elvégeztük a modell verifikálását és validálását. A verifikálás és az optimális végeleemes hálóméret meghatározása érzékenységvizsgálat segítségével történt. Esetünkben különösen fontos volt a hálóméret optimalizálása, hogy a várható nagyszámú futtatás mellett számítási idő a lehető legkevesebb legyen. A hálósűrűség a számítási igény és a feldolgozási idő mellett természetesen jelentősen befolyásolja az eredmények pontosságát is. A végeleemes analízis alapelvei szerint a pontosság javítása vagy a háló finomítását vagy magasabb rendű elemek alkalmazását jelenti, mivel a számítási eredmények pontosságát a végelelemek mérete nagyban meghatározza (Pisarciuc és társai, 2023). A finomabb háló használata fokozatosan növeli az eredmények pontosságát, amennyiben az alkalmazott végelelem típus megfelel a konvergencia-kritériumnak, ez is rávilágít a megfelelő elemméret kiválasztásának kritikus szerepére (Dutt, 2015). A finomabb végelelem háló tehát javítja a pontosságot, ugyanakkor több számítási erőforrást igényel és növeli a modell összetettségét, míg a durvább háló csökkentheti a pontosságot, de gyorsabb számítást tesz lehetővé (More, Bindu, 2015; Salehi, Burgueño, 2018). A Soroksári híd numerikus modellje kapcsán a hálóméret hatásának értékelését szisztematikus érzékenységi vizsgálattal végeztünk. A tipikus szerkezeti vastagságokat és a híd méretét figyelembe véve 0,20 m és 3,00 m közötti hálóméreteket elemeztük, és úgy találtuk, hogy a 0,5 m-es átlagos hálóméret jelenti az optimumot a pontosság és a számítási idő tekintetében.

A modell validálását a Budapesti Műszaki és Gazdaságtudományi Egyetem által a hídon 1990-ben végzett próbaterhelés eredményei alapján végeztük (Orosz és társai, 1990). A próbaterhelés során homokkal és kavicsal megtöltött KAMAZ 5511-es teherautókat használtak, amelyeket a helyszínen mérleltek a különböző terhelési elrendezések alkalmazása előtt. Példaképpen a 6. ábra a 3. teherállást szemlélteti, ahol a fekete alakzatok az aktív teherautók helyeit jelölik az adott terhelési elrendezésnél, a híd felső pályalemezén. A próbaterhelés során mért alakváltozásokat a 7. ábra mutatja be. A próbaterhelés során alkalmazott járműterhek és teherállások figyelembevételével a numerikus modellben is meghatároztuk a lehajlásokat és ezeket összevetettük a mért lehajlásokkal.


A 8. ábra a 3. teherállás esetén mért és számított lehajlások összehasonlítását mutatja. Összességében a mért és számított alakváltozások közötti legnagyobb különbség 4%-nál kevesebbre adódott, igazolva ezzel a modell alkalmazását a hídszerkezet viselkedésének nyomonkövetésére.

5. Gépi tanulás alkalmazása a hídmonitoring terén

A gépi tanulás (ML), a mesterséges intelligencia egyre növekvő részterülete, amely segítségével a tartószerkezetek állapotának nyomon követése reaktív folyamatból proaktív alakítható (Pisarciuc és társai, 2023; Dutt, 2015; More, Bindu, 2015). A hagyományos vizsgálati módszerekkel ellentétben, amelyek elsősorban az emberi szakértelemre és időszakos személyes jelenlétre támaszkodnak, az ML a szerkezet folyamatos felügyeletét teszi lehetővé a szenzorhálózatokon keresztül, amelyek nagy mennyiségű adatot képesek gyűjteni az alakváltozásról, a rezgésről és más tartószerkezeti paraméterekről (Salehi, Burgueño, 2018; Sofi és társai, 2022; Morgantini és társai, 2021). Ezek az adatok szolgálnak a többlépcsős ML folyamat alapjául, amely segítségével az intelligens szerkezeti monitoring (SHM) megvalósítható. A mérnöki ismeretek és a matematikai eljárások kombinációját




6. ábra: A 3. teherállásnál alkalmazott teherelrendezés felülnézete a híd próbaterhelése során (Orosz és társai, 1990)



7. ábra: A pályalemez próbaterhelése során mért alakváltozások a 3. számú teherállás esetén (Orosz és társai, 1990)

magában foglaló folyamat adatgyűjtéssel kezdődik, melynek során a szerkezetbe ágyazott érzékelők valós idejű információkat gyűjtenek. Ezeket a nyers adatokat előzetes feldolgozásnak vetik alá, hogy kiküszöböljék a zajt és a kiugró, irreális értékeket, amelyek ronthatják az elemzés pontosságát. Ezután következik a kívánt tartószerkezeti jellemzők kinyerése. Ezen kulcsfontosságú lépés során a károsodásra utaló releváns jellemzőket azonosítják és elkülönítik az előre feldolgozott adathalmazból (Flah és társai, 2021).

A kívánt paraméterek kinyerése után következik a modellalkotás, amely a gépi tanulás egyik legfontosabb része. A mesterséges neurális hálózatok (ANN), az emberi agy által inspirált ML algoritmusok egy olyan nagy teljesítményű típusa, amely különösen alkalmas az összetett adathalmazokban lévő mintázatok és trendek felismerésére (Morgantini és társai, 2021; Yaseen és társai, 2017; Kurian, Lijanapathirana, 2020). Ezeket a gépi tanulási algoritmusokat címkézett adathalmazok segítségével képezik ki, amely során minden egyes adatpontot egy adott károsodási állapothoz (pl. sérülésmentes, repedt, korrodált szerkezet, stb.) társítanak (Morgantini és társai, 2021; Malekloo és társai, 2022; Flah és társai, 2021). Az SHM számára az ún. felügyelt tanulás az egyik gyakran előnyben részesített módszer, mivel ez lehetővé teszi, hogy az ANN-ek megtanulják a szerkezeten mért jellemzők és a megfelelő károsodási jelenségek közötti bonyolult kapcsolatokat. Azokban az esetekben azonban, amikor kevés a címkézett adat, az ún. nem felügyelt tanulási technikák használhatók az anomáliák felismerésére és kiküszöbölésére. A betanítás után a modell szigorú validáláson megy keresztül, "nem látott" adatok felhasználásával, hogy valós helyzetekben is értékelni lehessen a modell hatékonyságát (Flah és társai, 2021). A "nem látott" adatok a modell számára olyan új adatok, amelyek nem voltak részei a tanulási folyamatnak. A megfelelően betanított modell ezután alkalmas a szerkezetből érkező adatok folyamatos megfigyelésére és értékelésére, továbbá szükség esetén riasztás is ad, ha potenciális károkra




8. ábra: A Soroksári híd mért és a számított lehajlásának a 3. számú teherállás esetére

utaló anomáliákat észlel. Ez a valós idejű visszacsatolás segíti a fenntartást végző mérnököket abban, hogy megalapozottabb döntéseket hozzanak a szükséges karbantartási és javítási munkálatokról, végső soron megelőzve ezzel a költségesebb meghibásodásokat és folyamatosan biztosítva a szerkezeti integritást (Salehi, Burgueño, 2018; Sofi és társai, 2021). A gépi tanulás tartószerkezeti állapotfigyelésben történő alkalmazása jelentős lehetőségeket rejt magában, de továbbra is fennállnak kihívások ezen a téren. A hatékony ML modellek képzéséhez megfelelő minőségű, címkézett adatokra van szükség, és a bonyolult, nem lineáris viselkedést mutató szerkezetek olyan robusztus modelleket igényelnek, amelyek képesek kezelni a magas fokú összetettséget (Morgantini és társai, 2021; Gu és társai, 2017). A digitális ikrek alkalmazása e tekintetben áthidaló megoldást jelenthet. A valós, fizikai szerkezetek virtuális másolatai segítségével több száz, vagy ezer véletlenszerű terhelési esetet vagyunk képesek szimulálni, és olyan adatokat generálni, amelyek szorosan tükrözik a híd valós viselkedését. Ilyen módon a digitális ikrekből származó, bőséges adatfolyam lehetővé teszi a kifinomult ML algoritmusok betanítását az SHM számára. Ez a lehetőség utat nyithat a kiemelt infrastruktúra műtárgyak prediktív karbantartásához, amelynél a gépi tanulási modellek nemcsak a károsodást képesek nagy pontossággal észlelni, hanem annak előrehaladását is képesek előre jelezni, és javaslatokkal segíthetik az optimális javítási stratégiák kidolgozását.

5.1. A Soroksári hídhoz alkalmazott neurális hálózat

Amint korábban említettük, a célunk a Soroksári híd felszerkezetének automatizált, intelligens monitoringja volt neurális hálózatok és digitális iker alkalmazása révén. Ehhez először végeeselemes modellezés segítségével egy adathalmazt hoztunk létre, ami tartalmazta egyrészt egy adott terheléshez tartozóan a szerkezet állapotát leíró fontosabb paramétereket (repedéstágasságok, feszültségek és alakváltozások), továbbá ezzel egy időben a valós szerkezeten elhelyezett szenzoroknak megfelelő pontokban a numerikus modellben számított – az adott szenzor típusának megfelelő – mennyiségeket. A munka során elsősorban a használhatósági határállapotokra vonatkozó jellemzőket vizsgáltuk, mivel a legtöbb tartószerkezetnél a használhatósági határértékek túllépése jellemzően megelőzi a komolyabb, teherbírás kimerülésével járó események kialakulását. A véletlenszerű terhelési esetek generálását Monte Carlo szimuláció segítségével végeztük. A terhek generálásának, azok numerikus modellbe való implementációjának, a modell futtatásának és az eredmények kigyűjtésének folyamatát egy Python programozási nyelv segítségével készített kóddal végeztük. A véletlen jellegű megoszló és koncentrált forgalmi



9. ábra: A véletlenszerű terhelés generálásához és automatizált végelemes analíziséhez készített Python kód folyamatábrája

terhek valószínűségi eloszlását, és az eloszlás paramétereit (várható érték és szórás) egy másik magyar közúti hídon mért forgalmi terhelési adatok alapján határoztuk meg. A generált terhelés numerikus modellbe történő implementálását és a 3D modell *AxisVM* szoftverben történő futtatását a *Pyaxisvm* nevű *Python* könyvtársegítségével, automatizált módon végeztük. A *Pyaxisvm* lehetővé teszi az *AxisVM* modell betöltését, a terhelések megadását, a hálógenerálást, az elemzés végrehajtását és az eredmények kinyerését, mindezt *Python* környezetben. A 9. ábra az alkalmazott *Python* kód munkafolyamatát szemlélteti.

A neurális hálózatok sikeres betanításának alapja a részletes adatelőkészítés. Mielőtt elkezdjük a tanítási folyamatot, az adatoknak tisztának, konzisztensnek és a hálózat hatékony tanulására alkalmasnak kell lenniük. Ez a döntő fontosságú első lépés, az úgynevezett előfeldolgozás olyan technikákat foglal magában, mint a normalizálás/skálázás, hogy minden paraméter hasonló skálán helyezkedjen el, megakadályozva ezzel, hogy a hálózat a nagyobb értékű jellemzők felé torzítson (Géron, 2019). A hiányzó értékeket imputálással pótolják (az adott változó hiányzó értékeit a változó megfigyelt értékeinek átlaga alapján adják meg) vagy eltávolítják, biztosítva, hogy a hálózat teljes információon alapuljon. A kiugró értékeket, azaz a normától jelentősen eltérő adatpontokat is kezelni kell, megakadályozandó azok torzító hatását a hálózat tanulási folyamatára. Az adatok előfeldolgozása és megfelelő formátumba való alakítása után a következő lépés az adatok felosztása, egy tanulási és egy tesztelési halmazra. Az adatok nagy részét (kb. 70-80%) jelentő tanulási halmaz az alapja a hálózat betanításának. A “nem látott” adatokat tartalmazó tesztalmaz (20- 30%) létfontosságú szerepet tölt be, mivel ennek felhasználásával értékeli a rendszer, hogy a hálózat képes-e általánosítani a megtanultakat új adatokra, nem csak a tanulási adatokat memorizálta (Chollet, 2017). Az adatok gondos előfeldolgozásával és felosztásával jól strukturált tanulási környezetet hozunk létre a neurális hálózat számára, ami robusztus és általánosítható teljesítményt eredményez az új (a tanulási folyamat részét nem képező) adatokon.

A Soroksári híd digitális ikertestvérén számolt, illetve a valós hídon mért adatokat a fentiek szerint előzetesen feldolgoztuk. Adatszűrési technikák alkalmazásával, a károsodás szempontjából kritikus tartószerkezeti


csoomópontokhoz és felületekhez tartozó rész-adathalmazok kijelölésével biztosítottuk, hogy csak a releváns információk elemzésére kerüljön sor. A szűrést követően átfogó elemzést végeztünk, mely során összefoglaló statisztika készült a szűrt adathalmazban megfigyelhető tendenciák jellemzése érdekében. Ezután az adatmegjelenítési technikákat alkalmaztunk az adathalmaz vizuális elemzésére és a potenciális kiugró értékek azonosítására. Az adatok gépi tanulási modellezéshez való előkészítése érdekében funkcióskalázást is végrehajtottunk, ehhez a *Scikit-Learn* könyvtár *StandardScaler* funkcióját használtuk, amellyel – az adatok szabványosítása révén – biztosítható volt, hogy minden paraméter egyenlő mértékben járuljon hozzá a tanulási folyamathoz. Az adatok előfeldolgozására egy többretegű perceptron regresszor (*MLPRegressor*) modellt építettünk, majd ezt betanítottuk a skálázott tanulási adatok (X_{train} , Y_{train}) felhasználásával. A betanított modell általánosíthatóságát ezután a tesztadatokra (X_{test}) vonatkozó előrejelzések létrehozásával és elemzésével értékeltük. Az ML modell teljesítményének és pontosságának értékelésére az átlagos négyzetes hiba (Mean Square Error, MSE), az átlagos abszolút hiba (Mean Absolute Error, MAE) és az R^2 (determinációs együttható) értékeket használtuk. Végezetül a digitális iker alkalmazása révén betanított ML modell felhasználásával értékeltük a valós fizikai hídon mért szenzor adatokat, ezekből meghatározva a híd kritikus pontjaiban várható kihasználtságot repedéstágasság, alakváltozások és feszültségek tekintetében.

6. EREDMÉNYEK

A Soroksári híd intelligens monitoringja érdekében egy új módszertant alkalmaztunk, amelyben a mesterséges neurális hálózatokat (ANN) és a digitális iker technológiát kombináltuk, az előző fejezetekben leírt módon. A véletlen jellegű forgalmi terhelés figyelembevételére Monte Carlo-szimulációt alkalmaztunk, és minden legenerált teherelrendezés esetére elvégeztük a híd VEM analízisét. A futtatás időigényes volta miatt a minták teljes száma csak 1000 volt, de a teljes statisztikai eloszlás megfelelő közelítése érdekében speciális mintavételi technikát (Importance Sampling) alkalmaztunk, így a mintaszám megfelelőnek bizonyult. Minden – véletlen forgalmi terheléshez tartozó – végelemes futtatás során kiszámítottuk a szerkezet kritikus pontjaiban a kihasználtságot lehajlás, repedéstágasság és feszültségek tekintetében, így jellemezve a híd állapotát. Ezen adatok szolgáltak ANN algoritmus célváltozóiként. Minden futtatás során rögzítettük a virtuális monitoring pontokban mérhető – a valós szerkezeten lévő szenzorok adatainak megfelelő – mennyiségeket is. Ezek az adatok jelentették az ANN algoritmus bemeneti változóit. Az így kapott két adathalmazt az ANN modell tanítására használtuk fel (a VEM modell összes eredménye szerepel ebben az adathalmazban). Az adathalmazt egy tanulási halmazra és egy tesztalmazra osztottuk fel. A tanulási halmazt szolgált az ANN modell kifejlesztésére és betanítására, míg a tesztalmazt a modell teljesítményének értékelésére használtuk. Az ANN modell pontosságát a tesztalmaz tényleges értékeinek és a modell előrejelzéseinek összehasonlításával értékeltük. Ez az értékelés döntő fontosságú annak felmérésében, hogy a modell mennyire hatékonyan általánosít a “nem látott” adatokra vonatkozóan, és mennyire teljesít jól a “valós” körülmények között. A betanított mesterséges neurális hálózati

modellünk teljesítményének és pontosságának értékelése az előzőekben említett hibamérszámokra alapult. A tesztalmez segítségével kiszámítottuk a betanított modellel készített előrejelzésekre vonatkozó alapvető hibametrikákat. Az átlagos négyzetes hiba (MSE) a tényleges (mért) értékek és az előrejelzett értékek közötti átlagos négyzetes különbséget méri. Ez a metrika a nagyobb hibákat a különbségek négyzetre emelése miatt erősebben bünteti, átfogó képet nyújtva az előrejelzés pontosságáról. Az MSE négyzetgyökéből számított átlagos négyzetes hiba (RMSE) az előrejelzési hibák átlagos nagyságát mutatja, függetlenül a célváltozó skálájától. Az alacsonyabb RMSE érték nagyobb pontosságot jelent, ami a tényleges értékekhez közelebb álló előrejelzést tükröz. Az átlagos abszolút hiba (MAE) a tényleges és az előrejelzett értékek közötti abszolút különbségek átlagos nagyságát számítja ki, ami az előrejelzési hiba egyszerű mérszámát kínálja. A modellünk értékelése során kapott MSE=0,0261, RMSE=0,0610 és MAE=0,0451 értékek kellően pontos előrejelzést jelentenek, és a modell megfelelő hatékonyságára utalnak a gyakorlati alkalmazás szempontjából. A számított hibaarányok jelenleg – a szimulációk korlátozott száma mellett – is ígéretesek, ugyanakkor a szimulációk számának és a tanulási adatmennyiség jövőbeli növelésével tovább csökkenthetők, ezzel tovább pontosítva az előrejelzéseket. A 10. ábrán látható diagram a betanított mesterséges neurális hálózati modell teljesítményét mutatja be. A vízszintes tengely a szerkezeti jellemzők (feszültség, alakváltozás, repedéstágasság) tényleges értékeit ábrázolja, amelyeket a validált végeses elemes modell analízise alapján kaptunk, míg a függőleges tengelyen ugyanezen szerkezeti jellemzők ANN modell által előrejelzett értékei szerepelnek. Általánosságban az előrejelzett és a tényleges értékek közötti erős korrelációt az ábrán a bal alsó saroktól a jobb felső sarokig tartó átlós, 45°-os egyenes mentén koncentrálódó adatpontok jelzik. Az ábrán megadott piros vonal az említett referenciavonal, ami az előrejelzett és a tényleges értékek tökéletes egyezését jelzi. Esetünkben a meghatározott – különböző szerkezeti paraméterekhez tartozó – adatpontok elhelyezkedése pozitív korrelációt mutat a referenciavonal körül, ami azt jelzi, hogy az ANN modell képes volt felismerni a bemeneti paraméterek (virtuális monitoring pontokban számított jellemzők) és a kívánt kimeneti adatok (a híd állapotát leíró kihasználtság értékek) közötti alapvető összefüggéseket. Az adatpontoknak a 45°-os egyenes körüli szóródása arra utal, hogy a modell pontosságát még lehet finomítani.

Ellenőriztük, hogy a modell nem volt-e túlillesztve (túlillesztés akkor fordul elő, amikor a modell nem tud általánosítani, és helyette túlságosan szorosan illeszkedik a tanulási adathalmazhoz). A 11. ábra bal oldalán látható diagram a tanulási és validációs veszteséget szemlélteti a tanulási ciklusok számának függvényében. A folyamatosan csökkenő tanulási veszteség (kék színű görbe) egy jól teljesítő ANN modellre utal, ami képes volt hatékonyan felismerni a tanulási adathalmazokon belüli mintákat. Biztató, hogy a validációs veszteség (piros színű görbe) szintén csökkenő tendenciát mutat, ami arra utal, hogy a modell jól általánosított és elkerülte a túlillesztést. A 11. ábra jobb oldalán, illetve a 12. ábrán az ANN modell által előrejelzett és a VEM modellben ténylegesen számolt szerkezeti paraméter értékek összehasonlítása látszik. A 11. ábra jobb oldalán a repedéstágasságokra, a 12. ábra bal oldalán a feszültségekre, a jobb oldalán pedig a lehajlásokra vonatkozó becslült és tényleges értékek összevetése látszik, a híd egy-egy




10. ábra: Az ANN modell előrejelzési pontosságának szemléltetése, ami az előrejelzett és a tényleges értékek (feszültség, alakváltozás, repedéstágasság) közötti korrelációval fejezhető ki


kiválasztott pontjában. Látható, hogy az adatpontok az ideális átlós egyenes körül csoportosultak, ami jó ANN modellt, és megfelelő pontosságú előrejelzéseket jelent. Az ANN modell ez alapján képes a szerkezet minden kiválasztott pontjában meghatározni a fenti értékeket, és a megfelelő határértékek megadása mellett kiszámítani a vonatkozó kihasználtságokat, a virtuális monitoring pontokban számított adatokból. A tanult összefüggések alapján a modell képes a tényleges hídon lévő szenzorok által mért adatokat is feldolgozni, és a fizikai szerkezet állapotáról számszerű visszajelzést adni. Erre mutat példát a 13. ábra, ami a valós hídon mért szenzor adatok alapján, az ANN modell által becslült lehajlási és repedéstágassági kihasználtságokat mutatja a híd kiválasztott csomópontjaiban, egy 1 órás időtartam alatt (2023. július 7, 5:00-6:00).

7. ÖSSZEFOGLALÁS


Bemutattunk egy összetett módszert a vasbeton hidak statikai állapotának valós idejű becslésére a hídon mért szenzor adatok alapján. Az egyes mennyiségek közötti korrelációt a tényleges híd digitális ikertestvéreinek felhasználásával határoztuk meg. Monte Carlo szimulációval véletlenszerű terhelési eseteket generáltunk, és VEM analízissel meghatároztuk a szerkezet kihasználtságát a megfelelően kiválasztott csomópontokban és az említett SLS szerkezeti határállapotok esetén. Ezekkel egyidőben, a fizikai szerkezeten lévő szenzoroknak megfelelő virtuális monitoring pontokban lévő mennyiségeket is rögzítettük a modellben. A fenti adatsorok közötti korrelációt az alkalmazott ANN algoritmus segítségével határoztuk meg. A digitális ikertestvéren kapott korrelációs függvény alapján a tényleges híd szenzormérései feldolgozhatók, és a híd erőtani állapota valós időben becslhető. A bemutatott módszer képes folyamatos visszajelzést biztosítani a híd állapotáról, és amennyiben a rendszer problémát jelez, elvégezhető a híd részletesebb szemrevételezéses és műszeres vizsgálata, illetve szükség esetén a szerkezet javítása vagy megerősítése, ezzel megelőzve a súlyosabb szerkezeti problémákat és biztosítva a biztonságos működést.



11. ábra: Az ANN modell tanulási és validációs vesztesége a tanulási ciklusok számának függvényében (balra), a tényleges és az előrejelzett repedéstágasságok összevetése (jobbra)



12. ábra: Az ANN modell által előrejelzett és a tényleges feszültségek összehasonlítása (balra), az előrejelzett és a tényleges lehajlások összevetése (jobbra)



13. ábra: A valós hídon mért szenzor adatok alapján, az ANN modell által becslött lehajlási és repedéstágassági kihasznátságok a híd kiválasztott csomópontjaiban, 1 órás időtartam alatt (2023. július 7, 5:00-6:00)

8. HIVATKOZÁSOK

- Woodward, R., et al. (2001), "Bridge Management in Europe (BRIME)," European Commission, Directorate-General for Research and Innovation, Brussels.
- Huang, R. Y., Mao, I. S., and Lee, H. K. (2010), "Exploring the deterioration factors of RC bridge decks: A rough set approach," Computer-Aided Civil and Infrastructure Engineering, Vol. 25, No. 7, pp. 517-529, <https://doi.org/10.1111/j.1467-8667.2010.00665.x>
- Gharehbaghi, V. R., et al. (2022), "A Critical Review on Structural Health Monitoring: Definitions, Methods, and Perspectives," Archives of Computational Methods in Engineering, Vol. 29, No. 4, pp. 2209-2235, <https://doi.org/10.1007/s11831-021-09665-9>
- Shih, H. W., Thambiratnam, D. P., and Chan, T. H. T. (2009), "Vibration based structural damage detection in flexural members using multi-criteria approach," J Sound Vib, Vol. 323, No. 3-5, pp. 645-661, <https://doi.org/10.1016/j.jsv.2009.01.019>
- Chang, P. C., Flatau, A., and Liu, S. C. (2003), "Review Paper: Health Monitoring of Civil Infrastructure," Struct Health Monit, Vol. 2, No. 3, pp. 257-267, <https://doi.org/10.1177/1475921703036169>
- Housner, G. W., et al. (1997), "Structural Control: Past, Present, and Future," J Eng Mech, Vol. 123, No. 9, pp. 897-971, [https://doi.org/10.1061/\(ASCE\)0733-9399\(1997\)123:9\(897\)](https://doi.org/10.1061/(ASCE)0733-9399(1997)123:9(897))
- Sun, L., Shang, Z., Xia, Y., Bhowmick, S., and Nagarajaiah, S. (2020), "Review of Bridge Structural Health Monitoring Aided by Big Data and Artificial Intelligence: From Condition Assessment to Damage Detection," Journal of Structural Engineering, Vol. 146, No. 5, [https://doi.org/10.1061/\(ASCE\)ST.1943-541X.0002535](https://doi.org/10.1061/(ASCE)ST.1943-541X.0002535)
- Liu, Z., Shi, G., Zhang, A., and Huang, C. (2020), "Intelligent tensioning method for prestressed cables based on digital twins and artificial intelligence," Sensors (Switzerland), Vol. 20, No. 24, pp. 1-20, <https://doi.org/10.3390/s20247006>
- Grievies, M. (2014), "Digital Twin: Manufacturing Excellence through Virtual Factory Replication," White Paper, Florida Institute of Technology. Vol. 1, No. March, pp. 1-7.
- Pregnotato, M., et al. (2023), "Digital twins for civil infrastructure: A case study on the Clifton suspension bridge (Bristol, UK)," in Life-Cycle of Structures and Infrastructure Systems, CRC Press, London, pp. 2219-2226, <https://doi.org/10.1201/9781003323020-271>
- Ladj, A., Wang, Z., Meski, O., Belkadi, F., Ritou, M., and Da Cunha, C. (2021), "A knowledge-based Digital Shadow for machining industry in a Digital Twin perspective," J Manuf Syst, Vol. 58, pp. 168-179, <https://doi.org/10.1016/j.jmsy.2020.07.018>
- Roszevák, Zs., Haris, I. (2021), "Modern numerical modeling of reinforced concrete structures," Concrete Structures, Vol. 22, pp. 13-20, <https://doi.org/10.32970/CS.2021.1.3>
- Ye, C., Zhang, Y., and Wang, Y. (2019), "A Digital Twin of Bridges for Structural Health Monitoring," in Structural Health Monitoring 2019, DEStech Publications, Inc., Lancaster, PA, <https://doi.org/10.12783/shm2019/32287>
- Pisarciuc, C., Dan, I., and Cioară, R. (2023), "The Influence of Mesh Density on the Results Obtained by Finite Element Analysis of Complex Bodies," Materials, Vol. 16, No. 7, p. 2555, <https://doi.org/10.3390/ma16072555>
- Dutt, A. (2015), "Effect of Mesh Size on Finite Element Analysis of Beam," International Journal of Mechanical Engineering, Vol. 2, No. 12, pp. 8-10, <https://doi.org/10.14445/23488360/IJME-V2I12P102>
- More, S. T., Bindu, R. S. (2015), "Effect of Mesh Size on Finite Element Analysis of Plate Structure", International Journal of Engineering Science and Innovative Technology (IJESIT), Volume 4, Issue 3, pp. 181-185
- Salehi, H., and Burgueño, R. (2018), "Emerging artificial intelligence methods in structural engineering," Eng Struct, Vol. 171, <https://doi.org/10.1016/j.engstruct.2018.05.084>
- Sofi, A., Regita, J. J., Rane, B., and Lau, H. H. (2022), "Structural health monitoring using wireless smart sensor network - An overview," Mech Syst Signal Process, Vol. 163, p. 108113, <https://doi.org/10.1016/j.ymssp.2021.108113>
- Morgantini, M., Betti, R., and Balsamo, L. (2021), "Structural damage assessment through features in quefreny domain," Mech Syst Signal Process, Vol. 147, p. 107017, <https://doi.org/10.1016/j.ymssp.2020.107017>
- Rizzo, P., and Milazzo, A., Eds. (2021), European Workshop on Structural Health Monitoring, Vol. 128, Springer International Publishing, Cham, <https://doi.org/10.1007/978-3-030-64908-1>
- Sahin, M., and Shenoi, R. A. (2003), "Quantification and localisation of damage in beam-like structures by using artificial neural networks with experimental validation," Eng Struct, Vol. 25, No. 14, pp. 1785-1802, <https://doi.org/10.1016/j.engstruct.2003.08.001>
- Gu, J., Gul, M., and Wu, X. (2017), "Damage detection under varying temperature using artificial neural networks," Struct Control Health Monit., Vol. 24, No. 11, p. e1998, <https://doi.org/10.1002/stc.1998>
- Yaseen, S. A., Aziz, O. Q., and Bakar, B. H. A. (2017), "Prediction of Shear Strength of Ultra High Performance Reinforced Concrete Deep Beams without Stirrups by Neural Network," Eurasian Journal of Science and Engineering, Vol. 3, No. 1, <https://doi.org/10.23918/eajse.v3i1s1p142>
- Malekloo, A., Ozer, E., AlHamaydeh, M., and Girolami, M. (2022), "Machine learning and structural health monitoring overview with emerging technology and high-dimensional data source highlights," Struct Health Monit, Vol. 21, No. 4, pp. 1906-1955, <https://doi.org/10.1177/14759217211036880>
- Flah, M., Nunez, I., Chaabene, W. B., and Nehdi, M. L. (2021), "Machine Learning Algorithms in Civil Structural Health Monitoring: A Systematic Review," Archives of Computational Methods in Engineering, Vol. 28, No. 4, pp. 2621-2643, <https://doi.org/10.1007/s11831-020-09471-9>
- Kurian, B., and Liyanapathirana, R. (2020), "Machine Learning Techniques for Structural Health Monitoring," in Lecture Notes in Mechanical Engineering, Springer, pp. 3-24, https://doi.org/10.1007/978-981-13-8331-1_1
- Géron, A. (2018), Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow, O'Reilly Media.
- Chollet, F. (2018), Deep Learning with Python, Manning Publications.
- Orosz, A. és társai (1990), „Az M0 autótű Soroksári Duna-ág hídja modernizálásának próbaterhelése,” tanszéki jelentés, Budapesti Műszaki és Gazdaságtudományi Egyetem, Vasbetonszerkezetek Tanszék, Budapest.

Asseel Al-Hijazeen (1994) okleveles építőmérnök, a Budapesti Műszaki és Gazdaságtudományi Egyetem (BME) hallgatója. Jelenleg PhD tanulmányait folytatja a BME Hidak és Szerkezetek Tanszékén. Kutatási területei: hidak intelligens monitoringja, a digitális iker és a gépi tanulás alapú megoldások, valamint a hidak károsodási folyamatainak automatizált azonosítási módszereinek felhasználásával. Tagja a *fib* Magyar Tagozatának és a Jordán Mérnökök Szövetségének.

Dr. Koris Kálmán (1970) okleveles építőmérnök, 1993-ban végzett a Budapesti Műszaki és Gazdaságtudományi Egyetem Építőmérnöki Karán, PhD, Egyetemi docens a BME Hidak és Szerkezetek Tanszékén. Kutatási területek: vasbeton szerkezeti elemek megbízhatóságának vizsgálata, előregyártott, előfeszített vasbeton szerkezetek analízise, szerkezetek megerősítése, faszervezetek analízise, numerikus modellezése. Tagja a *fib* Magyar Tagozatának. A Magyar Tudományos Akadémia köztestületének tagja. A Magyar Mérnöki Kamara, és az MMK Építési Tagozat elnökségének tagja. A *fib* Magyar Tagozata által kiadott Vasbetonépítés és Concrete Structures szakmai folyóiratok szerkesztője.