



MESTERSÉGESINTELLIGENCIA-ALAPÚ ÉPÍTÉSHELYI MINŐSÉGELLENŐRZÉS: AZ MI-TANÍTÁS TAPASZTALATAI ÉPÍTŐIPAR-SPECIFIKUS FELHASZNÁLÁSRA

AI-BASED ON-SITE CONSTRUCTION QUALITY CONTROL: EXPERIENCES IN TRAINING AI FOR CONSTRUCTION-SPECIFIC APPLICATIONS

Rák Olivér,¹ Bakai Nándor,² Mádér Patrik Márk,³ Etlinger József,⁴ Simon Dóra Erika,⁵ Jászberényi Tünde,⁶ Zagorác Márk Balázs⁷

Pécsi Tudományegyetem, Műszaki és Informatikai Kar, Mérnöki és Smart Technológiák Intézet, Mérnöki Ismeretek Tanszék, BIM Skills lab kutatócsoport/ Breuer Marcel Doktori Iskola, Pécs, Magyarország.

¹rak.oliver@mik.pte.hu; ²bakai.nandor@mik.pte.hu; ³mader.patrik@mik.pte.hu; ⁴etlinger.jozsef@mik.pte.hu
⁵simon.dora@mik.pte.hu; ⁶jaszberenyi.tunde@mik.pte.hu; ⁷zagoracz.mark@mik.pte.hu

Abstract

This study investigates the applicability of artificial intelligence in the construction industry, specifically focusing on the automation of on-site quality control through the training and fine-tuning of a YOLO-based segmentation model. The research presents the process of creating custom, construction-specific datasets within a Docker-based CVAT environment, highlighting the significance of the Human-in-the-Loop (HITL) methodology. To minimize human annotation time and prevent faulty feedback loops, the workflow was optimized using a custom Python script. By integrating the Douglas-Peucker algorithm and IoU-based filtering, this solution automatically smooths the fragmentation of AI-predicted polygons and eliminates duplicates. The results demonstrate that combining algorithmic cleaning of raw detection data with expert supervision is essential for developing reliable, industrial-grade AI solutions in the construction sector.

Keywords: computer vision, construction quality control, YOLO segmentation, Human-in-the-Loop (HITL).

Összefoglalás

Jelen tanulmány a mesterséges intelligencia építőipari alkalmazhatóságát, ezen belül az építéshelyi minőség-ellenőrzés automatizálását vizsgálja egy YOLO-alapú szegmentációs modell betanításán és finomhangolásán keresztül. A kutatás bemutatja az egyedi, falazásra fókuszált adathalmazok létrehozásának folyamatát egy Docker-alapú CVAT-környezetben, kiemelve a Human-in-the-Loop (HITL) metódus jelentőségét. Az emberi annotációs idő és a modell hibás visszacsatolásainak minimalizálása érdekében a munkafolyamatot egy egyedi Python-szkripttel optimalizáltuk. Ez a megoldás a Douglas-Peucker-algoritmus és az IoU-alapú szűrés integrálásával automatikusan simítja az AI által prediktált poligonok töredezettségét, és távolítja el a duplikátumokat. Az eredmények igazolják, hogy a nyers detektálási adatok algoritmikus tisztítása és a szakértői felügyelet kombinációja elengedhetetlen a megbízható, ipari minőségű MI-megoldások fejlesztéséhez az építőiparban.

Kulcsszavak: gépi látás, YOLO-szegmentáció, építéshelyi minőség-ellenőrzés.

1. Bevezetés

Az építőipar globális szinten az egyik legnagyobb gazdasági ágazat, ugyanakkor a digitalizáció és az automatizáció terén lemaradásban van

más iparágakhoz – például a feldolgozóiparhoz vagy az autóiparhoz – képest. A modern építőipari projektek komplexitásának növekedésével, valamint a szigorodó minőségi és biztonsági követ-

telményekkel párhuzamosan azonban az Ipar 4.0 technológiák integrációja elkerülhetetlenné vált. A mesterséges intelligencia (MI) és különösen a számítógépes látáshoz kapcsolódó (Computer Vision – CV) algoritmusok áttörést hoztak az építéshelyi folyamatok monitorozásában, a munkabiztonság növelésében és a minőség-ellenőrzésben. Az építéshelyi minőség-ellenőrzés klasszikus, manuális módszerei rendkívül idő- és erőforrás-igényesek, továbbá erősen függnek az ellenőrzést végző szakember szubjektív megítélésétől és pillanatnyi döntéshozatalától.

A gépi tanulásra (Machine Learning – ML) és mélytanulásra (Deep Learning – DL) épülő rendszerek képessé váltak arra, hogy az építési helyszínen rögzített vizuális adatokból (képekből, videókból, pontfelhőkből) valós időben azonosítsák az eltéréseket, hibákat és a biztonsági kockázatokat. Ugyanakkor ezen modellek – mint amilyenek a YOLO (You Only Look Once) objektumdetektáló architektúrák is – hatékonysága és ipari alkalmazhatósága egyenes arányban áll a betanításukhoz (training) használt adathalmazok minőségével és méretével. Különösen igaz ez a specifikus, magas komplexitású feladatoknál, mint amilyen a falazott szerkezetek minőség-ellenőrzése és szegmentációja. Az építőipari adatok gyakran strukturálatlanok, zajosak, és a megfelelő minőségű, kellő elemszámú (felcímkézett) tanító adatbázisok létrehozása jelentős akadályt képez az MI gyakorlati bevezetése előtt.

Jelen tanulmány célja a mesterséges intelligencia építőipari alkalmazhatóságának, ezen belül az építéshelyi minőség-ellenőrzés automatizálásának vizsgálata egy YOLO-alapú szegmentációs modell betanításán és finomhangolásán keresztül. A kutatás fókuszában a falazási munkálatokra specializált adathalmazok előállítása áll. A munkafolyamat egy Docker-alapú CVAT- (Computer Vision Annotation Tool) környezetben valósult meg, kiemelt figyelmet fordítva a Human-in-the-Loop (HITL)-metódusra. Mivel a kézi annotáció drága és lassú, a kutatás egy olyan optimalizált, Python-szkript-alapú megoldást mutat be, amely a Douglas–Peucker-algoritmus [1] és az Intersection over Union (IoU)-alapú szűrés integrálásával automatikusan simítja az MI által generált poligonok töredezettségét, valamint eltávolítja a redundáns duplikátumokat. A cikk azt a hipotézist vizsgálja és igazolja, hogy a nyers detektálási adatok algoritmikus tisztítása és a szakértői emberi felügyelet (HITL) megfelelő kombinációja elengedhetetlen a megbízható, ipari szintű minőség-ellenőrző MI-rendszerek kifejlesztéséhez.

2. Irodalmi áttekintés

A mesterséges intelligencia és a számítógépes látás építőipari alkalmazásának szakirodalma az elmúlt évtizedben exponenciális növekedést mutatott. A kutatások fókuszpontjai a biztonságtechnikai ellenőrzéstől az automatizált állapotfelmérésen át egészen a projektmenedzsment-rendszerekkel történő integrációig terjednek.

2.1. A mesterséges intelligencia és a BIM integrációja az építőiparban

Az építőipari MI-alkalmazások jelentős része az építményinformációs modellezés (Building Information Modeling – BIM) keretrendszeréhez kapcsolódik. Pan és Zhang [2] átfogó tanulmányukban rámutatnak, hogy a BIM és az MI integrációja kritikus a jövőbeli építési folyamatok automatizálásában, ahol az MI-alapú adatfeldolgozás kiegészíti a BIM statikus geometriai és szemantikai adatait. Ehhez hasonlóan, Zheng és munkatársai [3] a mélytanulási neurális hálózatok és a BIM integrációját vizsgálták a meglévő épületek állapotfelmérésének jövőbeni generációjában, bebizonyítva, hogy a vizuális adatok MI-vel történő feldolgozása nagymértékben növeli a felmérések pontosságát. A földalatti építkezések (alagútépítés) speciális, zárt és kockázatos környezetében Ninic et al. [4] vizsgálták a gépi tanulás és a számítógépes látás BIM-mel való szinergiáit, kiemelve a valós idejű monitorozás jelentőségét. Egy innovatív, játékosított megközelítést alkalmazva Boton et al. [5] egy olyan hibrid alkalmazást fejlesztettek ki, amely az építési projektek „on-demand”-felügyeletét teszi lehetővé a BIM és a gépi tanulás ötvözésével, ezáltal javítva a projektvezetők és a helyszíni folyamatok közötti információáramlást.

2.2. Adaptáció és implementációs kihívások az iparban

Bár a technológiai háttér adott, az ipari bevezetés (adoption) számos akadályba ütközik. Elghaish és társai [6] iparági szemszögből vizsgálták az MI-eszközök jelenlegi és jövőbeni alkalmazhatóságát, hangsúlyozva, hogy a tudáshiány és az adatkezelési protokollok hiánya a legfőbb gátló tényezők. A megelőző intézkedések és a munkabiztonság terén Muñoz-La Rivera et al. [7] elemezték az új technológiák (köztük az MI) bevezetésének megvalósíthatóságát. A bevezetés ösztönzőit tesztelve egy „light” deep learning-megközelítéssel, Abioye et al. [8] arra a következtetésre jutottak, hogy a számítási kapacitást kevésbé terhelő, optimalizált modellek elősegíthetik a technológia

szélesebb körű elterjedését a kivitelező cégek körében. Ezt a problémakört érinti Zhong et al. [9] kutatása is, akik az úgynevezett „kis mintás” (small samples) tanítási keretrendszereket vizsgálták építőipari baleseti jelentések információkinyerésére, rámutatva, hogy az adathiányos környezetben az adatok intelligens előkészítése és kiegészítése elengedhetetlen.

2.3. Mélytanulás a hiba- és hiányosságdetektálásban

Az építéshelyi minőség-ellenőrzés leggyakoribb MI-alkalmazása a hibadetektálás. Li et al. [10] egy szabványalapú deep learning-módszert fejlesztettek ki a homlokzati hibák kiértékelés-orientált detektálására, amely objektív mérőszámokat biztosít a javítási munkálatokhoz. A fókusz egyre inkább az előregyártott elemek (Off-Site Construction – OSC) felé is eltolódik: Kim és mtsai. [11] mélytanulás alapú képfelismerést alkalmaztak előregyártott vasbeton (PC) elemek repedéseinek detektálására és minőségvizsgálatára, jelentősen csökkentve az emberi ellenőrzés szükségességét. A minőség mellett a biztonság is kritikus: Wang et al. [12] a mélytanulást kiterjesztett valósággal (Augmented Reality – AR) kombinálták, hogy azonosítsák az állványzatok összeszerelési hiányosságait a helyszínen.

2.4. A YOLO-architektúra működési elve és fejlődése

A konvolúciós neurális hálózatok (CNN) között az objektumdetektálás egyik legjelentősebb mérföldkövét a 2016-ban bemutatott YOLO- (You Only Look Once) [13] architektúra jelentette. A hagyományos, kétfázisú régiójavaslat-alapú (region proposal) módszerekkel szemben a YOLO az objektumdetektálást egyetlen integrált regressziós problémaként fogja fel. A hálózat a teljes bemene-ti képet egy fázisban, egyetlen kiértékeléssel vizsgálja, felosztva azt egy rácsra (grid), majd ebből párhuzamosan prediktálja a befoglaló dobozokat (bounding boxes) és a hozzájuk tartozó osztály-valószínűségeket. Ennek az "egytékintetű" elvnek köszönhetően a YOLO kiemelkedő sebességgel (akár valós időben) képes működni, ami az építőipari gépi látás esetén kiemelten fontos.

Az elmúlt években az architektúra jelentős evolúción ment keresztül az építőipari alkalmazásokban. A legújabb kutatások [14] az épületek felületi hibáinak detektálására a YOLO korábbi, v8-as iterációit alkalmazták, normalizációalapú figyelemmechanizmussal kiegészítve. A folyamatos fejlesztések eredményeként az Ultralytics be-

mutatta az architektúra legújabb generációját, a jelen kutatásban is alkalmazott YOLO26-modellt [15]. A korábbi verziók (pl. v8, v11) esetében a hálózat gyakran rengeteg egymást átfedő keretet prediktált, amelyeket egy számításigényes utófeldolgozó algoritmussal, a Non-Maximum Suppression (NMS)-lépéssel kellett kiszűrni. A YOLO26 fő technológiai innovációja az „End-to-End” működési logika, amely teljesen kiiktatja az NMS-fázist, és közvetlenül a végleges detekciókat, valamint a szegmentációs maszkokat adja ki. Ez az architektúra drasztikusan felgyorsítja a modell futtatását, és növeli a pixelpontos maszkolási precizitást [15], ami kritikus előfeltétele a jelen vizsgálat fókuszát képező, nagyszámú és sűrűn elhelyezkedő falazóelem (tégla) robusztus szegmentációjának.

2.5. Kutatási hiányosság és a jelen vizsgálat relevanciája

Bár a szakirodalom kiterjedt figyelmet szentel a YOLO-alapú detektálásnak és a deep learning-modellek építőipari alkalmazásának, a tanulmányok többsége a kész modellek pontosságára fókuszál (bounding-box-alapú detektálás), és kevesebb figyelmet fordít az adat-előkészítés, a pixelpontos szegmentáció, valamint a betanítási fázis operatív kihívásaira. Az építéshelyi minőség-ellenőrzésnél – például a falazás fugáinak, tégláinak és esetleges kivitelezési pontatlanságainak ellenőrzésekor – nem elegendő egy befoglaló doboz (bounding box) megadása; precíz maszkolásra és szegmentációra van szükség. A szegmentációs adathalmazok generálása jelentős emberi erőforrást (annotációs időt) emészt fel.

A szakirodalomban azonosítható hiányosság egy olyan optimalizált, ipari gyakorlatba ültethető keretrendszer hiánya, amely a nyers mesterséges intelligencia által generált predikciókat (szegmentációs poligonokat) algoritmikusan finomítja, mielőtt azokat emberi szakértő elé tárná jóváhagyásra. Jelen kutatás ezt az űrt kívánja kitölteni azáltal, hogy a YOLO-alapú szegmentációt a Human-in-the-Loop (HITL)-módszertannal, valamint geometriai simító algoritmusokkal (Douglas–Peucker) és IoU-alapú tisztítással ötvözi, kifejezetten a falazási munkafolyamatok minőség-ellenőrzésére optimalizálva.

3. Kutatásmódszertan és iteratív modellfejlesztés

3.1. Problémafelvetés és a kutatás célja

A falazott szerkezetek minőség-ellenőrzésének távlati célja a téglakötések helyességének és a

falazat geometriai pontosságának automatizált, valós idejű vizsgálata. Jelen kutatás ezen átfogó rendszer első és legkritikusabb lépcsőfokát valósítja meg: egy mesterséges intelligencia- (MI) alapú számítógépeslátás-modell kifejlesztését, amely képes minden egyes beépített téglát nagy megbízhatósággal, pixelpontos szegmentációval detektálni a megfelelő térbeli pozíciójában. A feladat komplexitását az adja, hogy a téglák textúrája homogén, sűrűségük magas, ami jelentős kihívás elé állítja az objektumdetektáló algoritmusokat.

3.2. Adatgyűjtés és elsődleges annotáció (1. kör)

Az első lépés a nyers képi adatok rögzítése és a kiinduló adathalmaz létrehozása volt. Az adatok felcímkézése (annotálása) egy izolált, Docker-konténerben futtatott CVAT- (Computer Vision Annotation Tool) környezetben valósult meg (1. ábra). A kezdeti tanító adathalmaz létrehozása szigorúan manuális poligonannotációval történt. Az így kapott – viszonylag alacsony elemszámú – adathalmazon elvégeztük a YOLO- (You Only Look Once) architektúrára épülő szegmentációs modell elsődleges alapbetanítását.

A kezdeti eredmények és a validációs adatok rámutattak a hagyományos betanítás korlátaira: bár a modell képes volt detektálni a falazóelemek egy részét, jelentős anomáliák léptek fel. Számos téglát nem azonosított, a prediktált szegmentációs nyomvonalak túlzottan töredezetek (cickakosak) voltak, illetve a sűrű elhelyezkedés miatt gyakori volt az átfedés és a duplikáció ugyanazon a felületen.

3.3. Algoritmikus optimalizáció és a Human-in-the-Loop (HITL)-metódus

A modell által generált hibás és zajos kimenetek visszatanításának elkerülése érdekében egy

egyedi, Human-in-the-Loop (HITL) visszacsatolási hurkot és egy algoritmikus tisztító eljárást dolgoztunk ki. Az 1. körös modell által generált nyers predikciókat (pre-labeling) a CVAT-felületre történő visszatöltés előtt egy egyedi fejlesztésű Python-szkripttel dolgoztuk fel, amely két kritikus problémát orvosolt (2. ábra):


- Töredezettség csökkentése (Douglas–Peucker-algoritmus): A modell által generált, túlzottan sok pontból álló poligonokat a szkript a Douglas–Peucker-algoritmus segítségével algoritmikusan kisimította. A rendszer dinamikusan növelte az egyszerűsítés (epsilon) mértékét, amíg a poligonok pontszáma egy előre meghatározott, optimális maximum (pl. 10 pont/tégla) alá nem csökkent. Ezt kiegészítette a YOLO-modell nagy felbontású maszkgeneráló (retina_masks=True) funkciója.
- Duplikációk és átfedések szűrése (IoU-metszetvizsgálat): A hamis predikciók eltávolítására a szkript a Shapely geometriai könyvtárral kiszámította a poligonok közötti átfedést (Intersection over Union – IoU). A kritikus küszöbértéket meghaladó átfedések esetén az algoritmus a kisebb megbízhatóságú duplikátumot automatikusan elvetette.

Ezt a megtisztított adathalmazt töltöttük be a CVAT-ba, ahol a szakértői emberi felügyelet már csak a kimaradt téglák pótlására és minimális eligazításra korlátozódott, jelentősen felgyorsítva az annotációs folyamatot (méréseink alapján kb. 40%-os hatékonyságnövekedést értünk el).


3.4. Iteratív finomhangolás és a végleges modell

A kutatás során az adatok tisztítását és a modell továbbítását iteratív módon, a folyamatos minőségjavulás érdekében több (eddig összesen négy) körben végeztük el.

A köztes betanítási körök során a modell már megkapta a Douglas–Peucker- és IoU-algoritmusokkal tisztított, majd manuálisan felülvizsgált



1. ábra. CVAT-környezetben végzett felcímkézett fotó



2. ábra. HITL-metódust szemléltető ábra. „A” szkript futtatása előtti állapot, „B” szkript futtatását követő állapot

adatokat. A modell itt nem a saját korábbi hibáit (a töredezett poligonokat) tanulta vissza, hanem fokozatosan stabilizálta a geometriai határokat.

A negyedik, végső finomhangolási körnél értük el azt a stabil működést, amely a sűrű falazati struktúrában is képes volt a duplikációk kiküszöbölésére és a téglák egyértelmű szegmentációjára.

A többlépcsős iteráció igazolta, hogy a sorozatos algoritmikus szűrés, kombinálva a HITL-módszertannal, alacsony induló képszám mellett is képes finomítani a modellt és garantálni azt a pixelpontos szegmentációt, amely elengedhetetlen a későbbi falazati minőség-ellenőrzési algoritmusok futtatásához.

4. Eredmények és értékelés


A kutatás során bemutatott iteratív, Human-in-the-Loop (HITL)-alapú adatoptimalizáció hatékonyságát az ismételt betanítási körök kimeneti metrikái és vizuális predikciói igazolják. Az eredmények egyértelműen rámutatnak a Douglas-Peucker- és az IoU-alapú szűrés létjogosultságára a falazati szegmentáció során.

4.1. A modell tanulási dinamikája és konvergenciája


A többlépcsős finomhangolási folyamat stabilizálását a tanulási görbék validálják. A betanítási (train) és validációs (val) veszteségfüggvények analízise alapján megállapítható, hogy a modell mentes a túlilleszkedéstől. A befoglaló dobozok helyzetét értékelő veszteség (box_loss), valamint a pixelpontos maszkolást mérő veszteség (seg_loss) a betanítási ciklusok előrehaladtával meredeken csökkent (3. ábra). Ez azt jelenti, hogy az előkészített, töredezettségtől és duplikációktól mentes adathalmazzal a neurális hálózat redundáns információ nélkül, optimális gradiensereszkedéssel tudta elsajátítani a téglák geometriai jellemzőit.

4.2. Osztályozási pontosság és a tévesztési mátrix elemzése

A modell osztályozási megbízhatóságát a normalizált tévesztési mátrix (4. ábra) (Confusion Matrix) értékeli ki a legrészletesebben. A vizsgálat a háttér (background) és a célobjektum (tégla) elkülönítésére fókuszált. A mátrix adatai alapján a modell működőképes, 87%-os arányban (True Positive) azonosította helyesen a falazóelemeket. A háttér tévesztési aránya minimálisra csökkent, ami igazolja, hogy a falazat mögötti vizuális zaj, az esetleges habarcsmaradványok vagy az állványzat elemei csak részben zavarják meg a detektálást.



3. ábra. A YOLO szegmentációs modell betanítási (train) és validációs (val) veszteséggörbéi a 4. iteráció során. A grafikonok a befoglaló dobozok lokalizációs hibájának (box_loss), valamint a pixelpontos maszkolás veszteségének (seg_loss) egyenletes csökkenését és konvergenciáját mutatják, ami igazolja a stabil tanulási dinamikát és a túlilleszkedés (overfitting) elkerülését.



4. ábra. Normalizált tévesztési mátrix

4.3. Szegmentációs metrikák (mAP)

A finomhangolt hálózat végső teljesítményét a Mean Average Precision (mAP)-mutatók számszerűsítik. A negyedik iterációs kör végére a modell a szegmentációs maszkok tekintetében 60,3%-os mAP50 (0.603) pontosságot ért el. Ami ipari szempontból még relevánsabb: a rendkívül szigorú, a pixelpontos illeszkedést mérő mAP50-95 mutató 42,6%-ra (0.426) emelkedett. Bár a sűrű, homogén textúrájú építőanyagok felismerése általában véve is kihívást jelent a gépi látás számára, ez a drasztikus növekedés a nyers, első körös modell eredményeihez képest (ahol az érték mindössze ~32-36% körül stagnált) közvetlenül az algoritmikus élsimításnak (Douglas–Peucker) és a HITL-módszertannak köszönhető.

4.4. Vizuális predikciók és ipari alkalmazhatóság

A számszerű eredményeket a validációs adathalmazon lefuttatott vizuális tesztek is alátámasztják. A predikciós kimenetek elemzése során megállapítható, hogy a modell sikeresen azonosítja a falazóelemeket. Kiemelendő, hogy az előfeldolgozás során beállított szigorú IoU-szűrés eredményeként a sűrű falazati struktúrában megszűntek a duplikált maszkok. A prediktált poligonok élei egyenesek, és a lehetőségekhez mérten pontosan illeszkednek a téglák fizikai határaihoz.

5. Összegzés és konklúzió

Jelen tanulmány az építőipari gépi látás egyik feladatát, a falazott szerkezetek minőség-ellenőrzéséhez szükséges, mesterséges intelligencia-alapú tégladetektálást és szegmentációt vizsgálta. A kutatás rávilágított arra a technológiai problémára, hogy a nyers, dobozos YOLO szegmentációs modellek az építőipar homogén, textúrákban gazdag és sűrű környezetében nem képesek azonnali, ipari szintű megbízhatóságot nyújtani. A tisztítatlan adatokon végzett tanítás töredezett poligonokat és duplikált felismeréseket eredményez, ami a modell finomhangolása során csak a meglévő hibák konzerválódásához vezet.

A kutatás fő tudományos és gyakorlati hozzájárulása egy optimalizált Human-in-the-Loop (HITL)-munkafolyamat kidolgozása és validálása volt. Bizonyítást nyert, hogy a nyers MI-predikciók automatizált Python-szkriptekkel történő tisztítása – a Douglas–Peucker-algoritmussal történő poligonélsimítás és az IoU-alapú duplikátumszűrés – jelentősen felgyorsítja a CVAT környezetben végzett manuális annotációs munkát. A megtisztított ada-

tokon végzett iteratív betanítások eredményeként a modell felismerési pontossága szignifikánsan növekedett, a maszkokra vonatkozó mAP50 érték meghaladta a 60%-ot, miközben az annotálásra fordított emberi erőforrás a töredékére csökkent.

Összességében a bemutatott, adatközpontú MI-megközelítés ígéretes alapot szolgáltat az építőipari automatizáció számára. A jövőbeli kutatási irányok a jelenleg kifejlesztett, stabil detektálási modellre épülnek majd: a szegmentált poligonok geometriai elemzésével lehetővé válik a téglakötések szabályosságának, a falazat síkpontosságának, valamint a fugavastagságoknak a teljesen automatizált, valós idejű szoftveres ellenőrzése az építési helyszíneken, akár laikus megrendelők által is.

Köszönetnyilvánítás

A Kulturális és Innovációs Minisztérium, Nemzeti Kutatási, Fejlesztési és Innovációs Alapjából finanszírozott Egyetemi Kutatói Ösztöndíj Programjának szakmai támogatásával készült.

Szakirodalmi hivatkozások

- [1] D. H. Douglas, T. K. Peucker: *Algorithms for the Reduction of the Number of Points Required to Represent a Digitized Line or Its Caricature*. Cartographica, 10/2. (1973) 112–122.
<https://doi.org/10.3138/FMS7-6770-U75U-7727>
- [2] Y. Pan, L. Zhang: *Integrating BIM and AI for Smart Construction Management: Current Status and Future Directions*. Arch. Comput. Methods Eng., 30/2. (2023) 1081–1110.,
<https://doi.org/10.1007/s11831-022-09830-8>
- [3] Mani Amrouni Hosseini, Mehdi Ravanshadnia, Majid Rahimzadehan, Saeed Ramezan: *Next-Generation Building Condition Assessment: BIM and Neural Network Integration*. Journal of Performance of Constructed Facilities, 38/6. (2024)
<https://doi.org/10.1061/JPCFEV.CFENG-4828>
- [4] M. Q. Huang, J. Ninić, Q. B. Zhang: *BIM, Machine Learning and Computer Vision Techniques in Underground Construction: Current Status and Future Perspectives*. Tunnelling and Underground Space Technology, 108. (2021) 103677.
<https://doi.org/10.1016/j.tust.2020.103677>
- [5] F. Pour Rahimian, S. Seyedzadeh, S. Oliver, S. Rodriguez, N. Dawood: *On-Demand Monitoring of Construction Projects through a Game-Like Hybrid Application of BIM and Machine Learning*. Automation in Construction, 110. (2020) 103012.
<https://doi.org/10.1016/j.autcon.2019.103012>
- [6] F. Salih and I. El-adaway: *Current and Future Adoption of Artificial Intelligence Tools and Applications in Construction Projects: An Industry-Based Perspective*. In: Proceedings of the Canadian Society for Civil Engineering Annual

- Conference 2023, 5. (2024) 349–363.
https://doi.org/10.1007/978-3-031-61503-0_26
- [7] M. del R. Merino, M. S. Cañamares, M. Z. Calleja, A. R. Serrano, R. A. H. Morante: *Feasibility of Using New Technologies and Artificial Intelligence in Preventive Measures in Building Works*. Buildings, 15/12. (2025) 2132.
<https://doi.org/10.3390/buildings15122132>
- [8] M. Watfa, A. Bykovski, K. Jafar: *Testing Automation Adoption Influencers in Construction Using Light Deep Learning*. Automation in Construction, 141. (2022) 104448p.
<https://doi.org/10.1016/j.autcon.2022.104448>
- [9] D. Feng, H. Chen: *A Small Samples Training Framework for Deep Learning-Based Automatic Information Extraction: Case Study of Construction Accident News Reports Analysis*. Advanced Engineering Informatics, 47. (2021) 101256.
<https://doi.org/10.1016/j.aei.2021.101256>
- [10] J. Guo, Q. Wang, Y. Li: *Evaluation-Oriented Façade Defects Detection Using Rule-Based Deep Learning method*. Automation in Construction, 131. (2021) 103910.
<https://doi.org/10.1016/j.autcon.2021.103910>
- [11] S. Lee, M. Jeong, C.-S. Cho, J. Park, S. Kwon: *Deep Learning-Based PC Member Crack Detection and Quality Inspection Support Technology for the Precise Construction of OSC Projects*. Applied Sciences, 12/19. (2022) 9810.
<https://doi.org/10.3390/app12199810>
- [12] R.-J. Dzung, C.-W. Cheng, C.-Y. Cheng: *A Scaffolding Assembly Deficiency Detection System with Deep Learning and Augmented Reality*. Buildings, 14/2. (2024) 385.
<https://doi.org/10.3390/buildings14020385>
- [13] J. Redmon, S. Divvala, R. Girshick, A. Farhadi: *You Only Look Once: Unified, Real-Time Object Detection*. In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Jun. 2016, 779–788.
<https://doi.org/10.1109/CVPR.2016.91>
- [14] X. Lin et al.: *Building Surface Defect Detection Based on Improved YOLOv8*. Buildings, 15/11. (2025).
<https://doi.org/10.3390/buildings15111865>
- [15] J. Glenn, Q. Jing: *Ultralytics YOLO26*. Accessed: Mar. 14, 2026.
<https://github.com/ultralytics/ultralytics>