

# Mesterséges Intelligencia alkalmazása a képalkotó vizsgálatok értékelésében

Application of Artificial Intelligence in the evaluation of NDT imaging

Dudra Judit<sup>a</sup>, Zsíros Zsombor<sup>b</sup>, Margitai Péter<sup>c</sup>, Pataki Márton<sup>d</sup>, Szávai Szabolcs<sup>e</sup>,  
Matók Viktor<sup>f</sup>, Balogh Csilla<sup>g</sup>, Viczena Julianna<sup>h</sup>, Béres Bence<sup>i</sup>

<sup>a-e</sup>Bay Zoltán Alkalmazott Kutatási Közhasznú Nonprofit Kft.,

<sup>a</sup>vezető kutató, judit.dudra@bayzoltan.hu, <sup>b</sup>senior kutató, zsombor.zsiros@bayzoltan.hu, <sup>c</sup>fejlesztő, peter.margitai@bayzoltan.hu,

<sup>d</sup>MI fejlesztő, marton.pataki@bayzoltan.hu, <sup>e</sup>osztályvezető, szabolcs.szavai@bayzoltan.hu

<sup>f-g</sup>Metalcontrol Kft., <sup>f</sup>operatív igazgató, matok.viktor@metalcontrol.hu, <sup>g</sup>metallográfiai vizsgálatvezető, balogh.csilla@metalcontrol.hu

<sup>h-i</sup>Euroil Kft., <sup>h</sup>projektvezető, viczena.julianna@euroil.eu, <sup>i</sup>operatív igazgató, beres.bence@euroil.eu

## Kulcsszavak

roncsolásmentes anyagvizsgálat, hegesztett kötés, radiográfiai (röntgen) vizsgálat, mesterséges intelligencia (MI), szabvány szerinti kiértékelés

## Keywords

non-destructive material testing, welded joint, radiographic (X-ray) examination, artificial intelligence (AI), evaluation according to standard

## Absztrakt

A jelenlegi radiográfiai hibakereső vizsgálat manuális kiértékelésen alapszik, humán erőforrás igényes, minőségbiztosítása kellő mértékben nem biztosított és súlyos kapacitáskorlátokkal is terhelt. Az eredményeket az elemzés után külön lépésben kell digitálisan rögzíteni, mely hibákat vihet a folyamatba. Ezért mind a hatékonyság, mind a megbízhatóság növelése érdekében célszerű és indokolt a folyamat automatizálása. Ennek eredményeként jelen tanulmány egy olyan egységes, az iparági elvárásoknak megfelelően megbízható és további adatbányászati megoldásokhoz csatlakozható vizsgálati rendszert mutat be, mely a fent felsorolt igényeket törekszik kielégíteni.

## Abstract

The current radiographic flaw detection test is based on manual evaluation, requiring significant human resources. Quality assurance is not adequately ensured, and there are also serious capacity constraints. The results need to be digitally recorded as a separate step after analysis, which can introduce errors into the process. Therefore, for the purpose of increasing both efficiency and reliability, it is advisable and justified to automate the process. As a result, this study presents a unified examination system that meets industry expectations, is reliable, and can be integrated with additional data mining solutions, aiming to satisfy the mentioned requirements.

## 1. Bevezetés

A roncsolásmentes vizsgálatok kiemelt szerepet játszanak a hegesztett kötések tartalmazó szerkezetek integritásának biztosításában azáltal, hogy lehetővé teszik azok minőségének megfelelő ellenőrzését anélkül, hogy károsítanák vagy gyengítenék a vizsgált szerkezetet. Számos iparágban és országban szigorú szabályozások és szabványok határozzák meg a hegesztett szerkezetek roncsolásmentes vizsgálatát és azok értékelési követelményeit.

A vizsgálatok lehetővé teszik a szakemberek számára, hogy például radiográfiai filmek alapján meghatározható legyen az eltérések, folytonossági hiányok geometriai mérete, elhelyezkedése és terjedelme. Ez kritikus információ a hibák súlyosságának felméréséhez és az esetleges javítások meghatározásához, kezeléséhez.

A röntgenvizsgálatokból származó nagyszámú képi adatok gyors és hatékony elemzését, majd kiértékelését támogatva célul tűztük ki egy szabványkövetelmények szerinti komplex képelemző és kiértékelő alkalmazás (szoftver) fejlesztését fémek és ötvözetek elemzésére, mely a belső-külső forrásból származó képi eredmények minél teljesebb körű mesterséges intelligencián (MI) történő kiértékelésén alapszik. Így a képelemző és kiértékelő szoftver egyedülálló módon nyújt támogatást a mezoszkopikus eltérések (pl. zárványok) széles spektrumú mélyelemzéséhez.

## 2. Alkalmazás architektúra

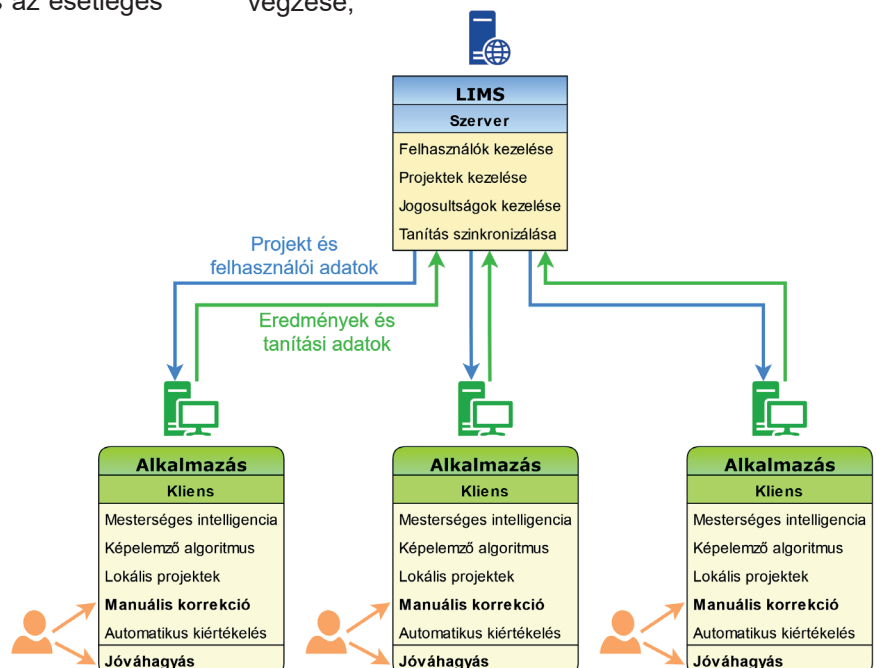
A fejlesztés során elvárás volt, hogy a képelemző és kiértékelő alkalmazás (szoftver), egy már meglévő adatbázis rendszerhez, az euris-LIMS: Euroil Global

Information System - Laboratory Information Management System Modulhoz (továbbiakban LIMS-hez) kapcsolódjon. A szoftver futásakor a LIMS látja el a felhasználók azonosítását, biztosítja a szoftver adatbázisát, kezeli a rögzített projekteket és jogosultságokat, majd tárolja a kiértékelte eredményeket.

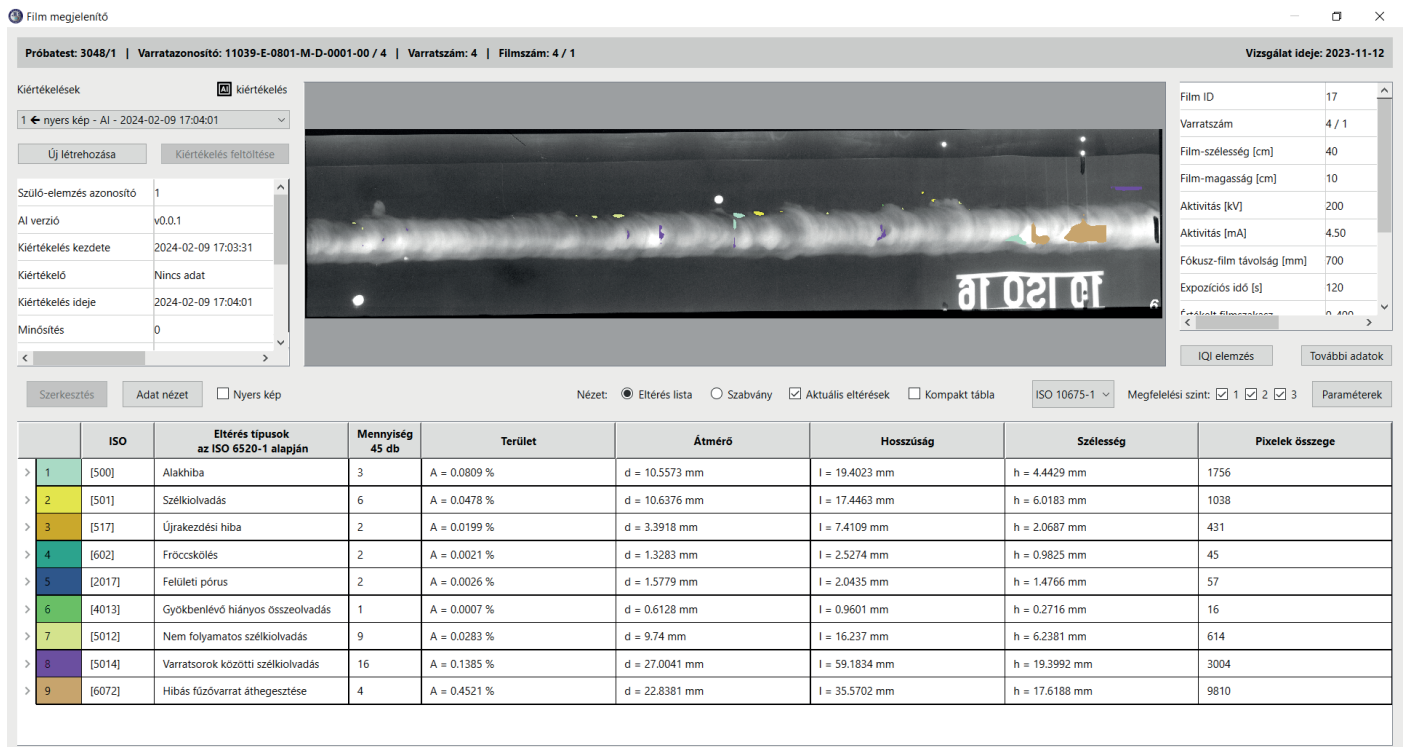
Ezzel párhuzamosan a képelemző kliens alkalmazás a LIMS rendszerrel oda-vissza kommunikációt végez, lokális gépen futtatható, így a számítógépek elemzés közben függetlenek egymástól. Ennek folyamatát szemlélteti az 1. ábra.

A kliens alkalmazás feladata a

- mesterséges intelligencián alapuló képelemzés elvégzése,



1. ábra: Képelemző és kiértékelő alkalmazás főbb funkciók



2. ábra: Röntgenfilm megjelenítő ablak MI elemzés után, eltérések

- folyamatok/adatok kezelése, kommunikáció a LIMS-szel (projektek/felhasználók letöltése, eredmények feltöltése),
- szakértő (felhasználó) által történő manuális képkorrekció végzése (szakértői szupervízió),
- szabvány szerinti automatikus kiértékelés,
- eltérések listázása, eredmények megjelenítése,
- manuális jóváhagyás és tovább tanítási lehetőség biztosítása.

### 3. Alkalmazás munkafolyamata – workflow

Az alkalmazás indítását követően a LIMS szerverről letöltődnek a projektek és az azokhoz tartozó próbatetek. A projektekhez rendelt próbatetekhez hegesztési varratok adatai és a varratokhoz kapcsolódó vizsgálatok információi, továbbá ezen belül a vizsgálatok röntgen képi elemei (filmek) tartoznak.


#### 3.1 Eltérések mesterséges intelligencia alapú kiértékelése

Egy film betöltésekor megjelenik a kiválasztott röntgenkép felvétel a hozzá tartozó metaadatokkal, melyet a 2. ábra szemléltet. Ekkor a felhasználó mesterséges intelligencián alapuló képelemzést indíthat. Az MI elemzés befejezése után a megtalált eltérések kiértékelése – az eltérések geometriai paramétereivel – azonnal megjelenik (lásd 2. ábra táblázatában a különböző színnel jelölt alakhiba, szélkiolvadás stb. eltéréslistát).

#### 3.1.1 Alkalmazott mesterséges intelligencia

A képszegmentálás egy alapvető gépi látás feladat, amelynek célja egy képet több értelmes és szemantikailag egységes régióra bontani. A képszegmentálási módszerek értékes információk kinyerésére törekednek a képekből azáltal, hogy pixelenként megkülönböztetik a különböző objektumokat vagy releváns területeket. Elmondható, hogy napjainkban a gépi tanulási módszerek forradalmasították a 2D kép szegmentálását, és széles skálájú technikákat kínálnak a különböző szegmentációs kihívások megoldására.

Jelen képelemző szoftver úgynevezett U-Net és ResNet architektúrát használ a röntgenképek szegmentációja során. Előbbi nevét az U alakú hálózati felépítéséből kapta és 2015-ben javasolta orvosbiológiai képeken található alakzatok elkülönítésére Ronneberger és társai [2] (3. ábra), utóbbiról a tanítóadatok fejezet alatt számolunk



3. ábra: U-Net architektúra mintaváza [2]

be részletesebben. Az U-Net architektúra egy kódoló-dekódoló struktúra, amelyet úgy alakítottak ki, hogy kiemelkedő teljesítményt nyújtson a pixelenkénti szegmentációs feladatokban. A hálózat kódoló része hasonlít egy hagyományos konvolúciós neurális hálózathoz (CNN), és kulcsszerepet játszik a tulajdonságok hierarchikus kinyerésében. Fokozatosan csökkenti a térbeli felbontást, miközben növeli a tulajdonságcsatornák számát. Eközben a hálózat dekódoló része a felskálázást végzi, és előállítja a pixelenkénti előrejelzéseket. Fokozatosan növeli a térbeli felbontást, miközben csökkenti a tulajdonságcsatornák számát.

Az U-Net fontos újítása az úgynevezett "kihagyási" kapcsolatok bevezetése, amelyek lényeges kapcsolatot teremtenek az előfeldolgozó és visszafejtő rétegek közt. A "kihagyási" kapcsolatok a kódolóból közvetlenül átadják a tulajdonságtérképeket a dekóder megfelelő rétegeinek. Ez segít megőrizni a finom részleteket és a térbeli információt, amelyek máskülönben elveszthetnének a csökkentés és a felskálázás folyamatában.

A kódoló, amelyet gyakran a tömörítő útvonalként emlegetnek, konvolúciós rétegek sorozataként kezdődik, amelyeket aktivációs függvények (általában ReLU - rectified linear unit) és maximum-kiválasztás rétegek követnek. Ez az útvonal fokozatosan csökkenti a térbeli dimenziókat. Ellenkezőleg, a dekóder, amit a bővítő útvonalnak is neveznek, transzponált konvolúciós rétegekből (amelyeket gyakran dekonvolúciós vagy felskálázó rétegeknek is hívnak) áll, amelyek fokozatosan növelik a térbeli dimenziókat. A dekóder minden szintjén a kódoló útvonalból származó tulajdonság térképeket a dekóder által előállított térképekkel összefűzi, ami hatékonyan növeli a részletes információk megőrzését.

A fejlesztés során alkalmazott mesterséges intelligencia modell első lépésben bináris (hiba-nem hiba) klasszifikációt (osztályozást) végez, majd az elemzés során ennek a modellnek az alapjaira épül a következő lépés (architekturális szinten), ami már kategóriákra (eltérésekre) szétbontva végzi a röntgenképek szegmentációját és elemzi az eltérések geometriai tulajdonságait.

### 3.1.2 Tanítóadatok – optimalizálás

A tanítóadatoknak kiemelkedő szerepük van a képszegmentálás során, mivel ezek adatai segítik a gépi látó algoritmust az értelmes és pontos szegmensek kialakításában. A megfelelő metaadatokkal jól ellátott, esetünkben

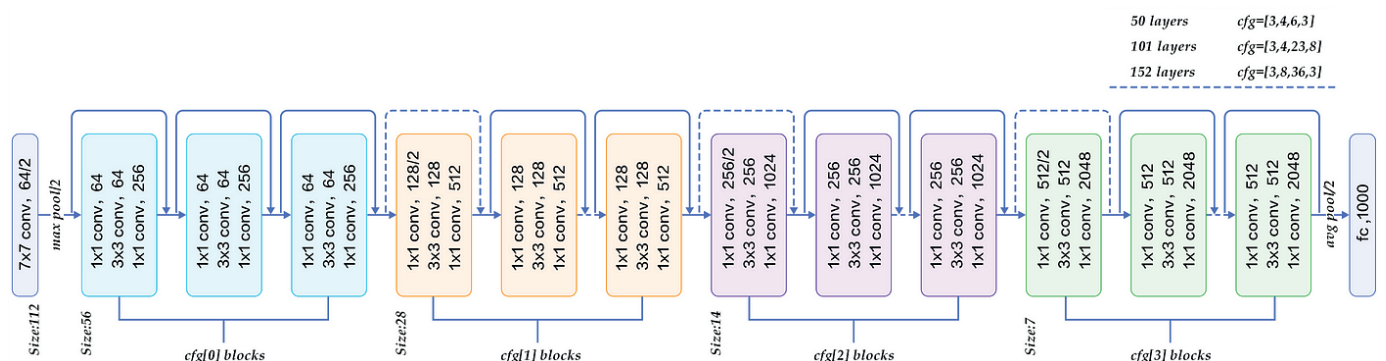
a szakemberek által megfelelően jelölt (labelezett) tanítóadatok nélkülözhetetlenek a képszegmentálási modell sikeres tanításához és hatékony működéséhez, mivel ezek az adatok adják meg a referenciapontokat a különböző objektumok és területek megfelelő azonosításához. A modell a tanítóadatok alapján tanulja meg a különböző színeket, ezzel a röntgenképen megjelenő eltéréseket és formákat. A megfelelően összeállított tanítóadatok hozzájárulnak a modell pontosságához és kiszámíthatóságához, melyek alapján a modellek teljesítménye értékelhető és javítható. Az éles és jól meghatározott tanítóadatok segítik azokat a visszajelzéseket, amelyek révén a modell tovább finomítható és optimalizálható.

A bináris klasszifikációt végző U-Net mesterséges intelligencia tanításához a rendelkezésre álló röntgenkép adatokat 256x256 pixel nagyságú kép négyzetekre bontottuk fel. Ezzel egyrészt a röntgenképek nem konzisztens mérete egységes szeletekre osztható, ezáltal a tanítóadatok mennyisége tovább nő, illetve a kis és egységes képszelet méret megfelelőbb a neurális hálózat hatékonyságának és taníthatóságának szempontjából.

Az U-Net architektúrában kódoló/tömörítő elemként a RegNet nevű konvolúciós neurális hálózatmodell került alkalmazásra [3]. Esetünkben a RegNet modell alkalmazásával a kódoló/tömörítő rész felelős a kép alacsony szintű jellemzőinek kinyeréséért és tömörítéséért. Ebben a kontextusban a RegNet konvolúciós rétegei vagy blokkjai szolgálnak a bemeneti képelemek kódolására, ami a magasabb szintű absztrakciókat tartalmazzák. Ezután az U-Net struktúrája további részekkel (dekóderekkel) dolgozik az eredeti kép részletes szegmentálásáért.

A tanítás optimalizációs algoritmus a Dice Loss volt. A Dice Loss a szegmentált terület és a valóságos (referencia) terület átfedését méri, és ennek alapján számolja ki a veszteséget, majd az optimalizáció során az eredményeket kategóriánként súlyozza az előfordulási gyakoriságukkal arányosan. Ez az optimalizációs megoldás a kategóriákra (eltérésekre) bontott tanítás során kifejezetten fontos szerepet töltött be, mivel a különböző hegesztési eltérések között nagyságrendbeli mennyiségi különbségek vannak.

Az alkalmazásban a bináris osztályozás utáni eltérés klasszifikációt végző modell feltanításához ResNet architektúra került alkalmazásra (4. ábra), mely mélytanulási áttörést jelent, különösen a képosztályozási feladatokban, mely 2016-ban került először publikálásra [5].



4. ábra: ResNet architektúra mintaváza [4]

A röntgenképek eltérés klasszifikációjának alapját az MSZ EN ISO 6520-1:2007 szabvány [1] által szolgáltatott eltéréstípusok nyújtják. A Microsoft kutatói által kifejlesztett ResNet a nagyon mély neurális hálózatok feltanításának problémáját oldja meg. A hagyományos mély hálózatoknál a probléma abban jelentkezett, hogy a további rétegek nem járultak hozzá a teljesítmény javulásához, néha pedig a tanítási hatékonyság csökkenéséhez vezettek. A ResNet ezt a maradék tanulás bevezetésével oldja meg, ahol a rétegek a réteg bemeneteire vonatkoztatva tanulják meg a függvényeket, ahelyett, hogy önmagukban referált függvényeket tanulnának. Ez lehetővé teszi a korábban használnál jelentősen mélyebb hálózatok sikeres betanítását, jelentős pontossági javuláshoz vezetve.

A klasszifikációs modell bemenete 128\*128 pixel méretben került meghatározásra. A tanítás során az információ veszteség mérésére szolgáló Cross Entropy Loss eljárás került alkalmazásra ADAM (adaptive moment estimation) optimalizációs algoritmussal kiegészítve.

A tanítás folyamán számos kérdés merül fel, melyek kezelése kulcsfontosságú. Gondolunk itt például a röntgenképeken látható eltérések átfedéseire, melyek pontatlan felismerése a folyamatosan gyarapodó képi adatmennyiség és tanítóadatok révén kiküszöbölhetővé válik és feltanulhatóak.

### 3.2 Manuális korrekció – szerkesztő modul

Az MI által készített kiértékelést az alkalmazás automatikusan feltölti a LIMS rendszerbe, ám bár annak eredményét a szoftverbe épített manuális korrekció (szerkesztő modul) funkcióval bármikor módosíthatja, felülírhatja a felhasználó. A szoftver megkülönbözteti az MI és a felhasználók által tett elemzéseket, melyek verziókövetéssel

visszatölthetőek.

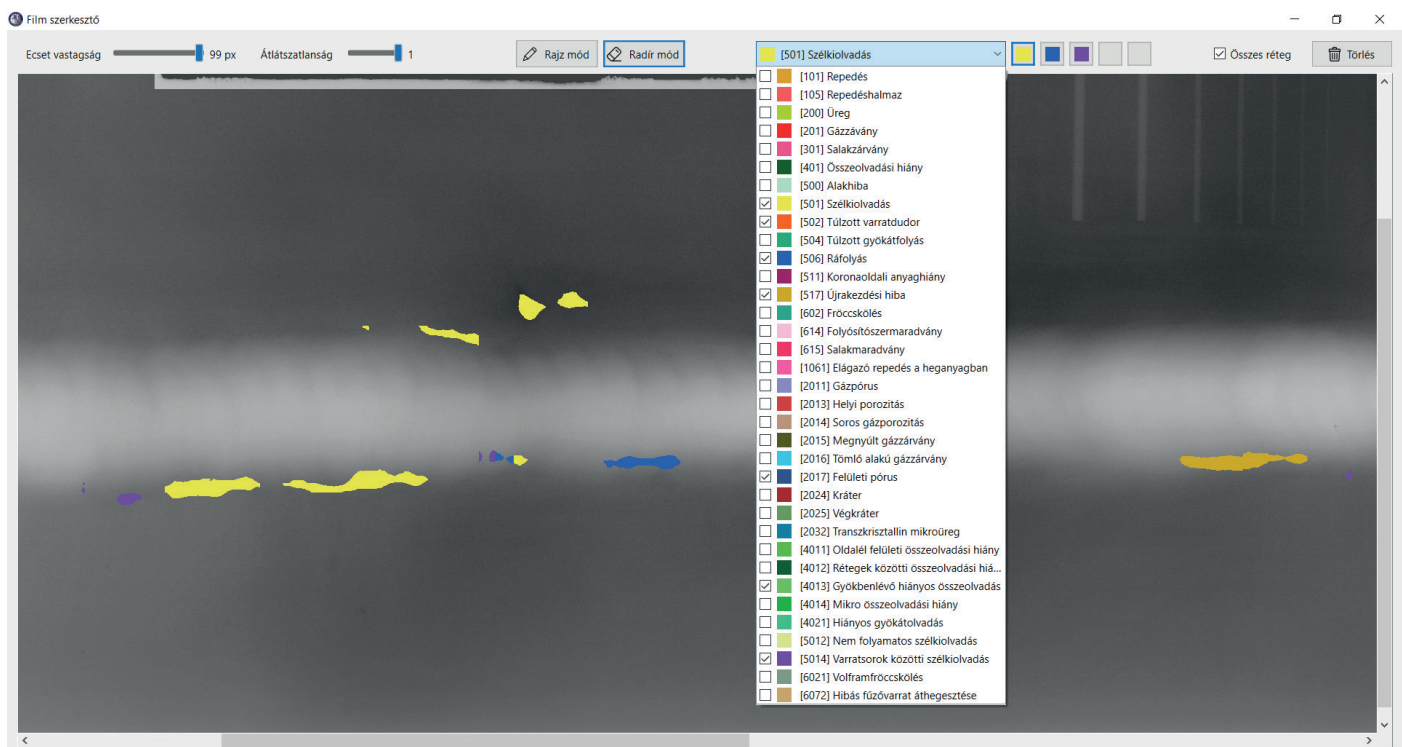
A szerkesztő modulban (ld. 5. ábra) a

- röntgenkép nagyítható és mozgatható, lehetővé téve a varrat részleteinek alaposabb vizsgálatát. Ez a funkció nem csak a röntgenképen látható különbségek szerkesztéséhez és újra rajzolásához, hanem a varratkép mélyebb elemzéséhez is hasznos.
- A röntgenképeken található eltérések átlátszósága csúszka segítségével állíthatóak, ez átfedések esetében segítség a felhasználó számára,
- illetve az eltérések rétegenként ki-be kapcsolhatók.
- A jelölések során az ecsetvastagság változtatható, míg az eltérések típusa egy lenyíló listából kiválasztható, melyen belül egy jelölőnégyzet mutatja az adott réteg röntgenképen történő láthatóságát.
- A szerkesztés során makro gombok jelzik a legutóbb használt eltérés kategóriák listáját, mely által gyors és hatékony váltás valósítható meg az eltérések közötti szerkesztések során.
- Összes jelölő négyzet bepipálása után a rétegek egyszerre törölhetőek.
- A szoftverhez új eltérés kategóriák definiálhatóak esetleges új szabvány bevezetése kapcsán.

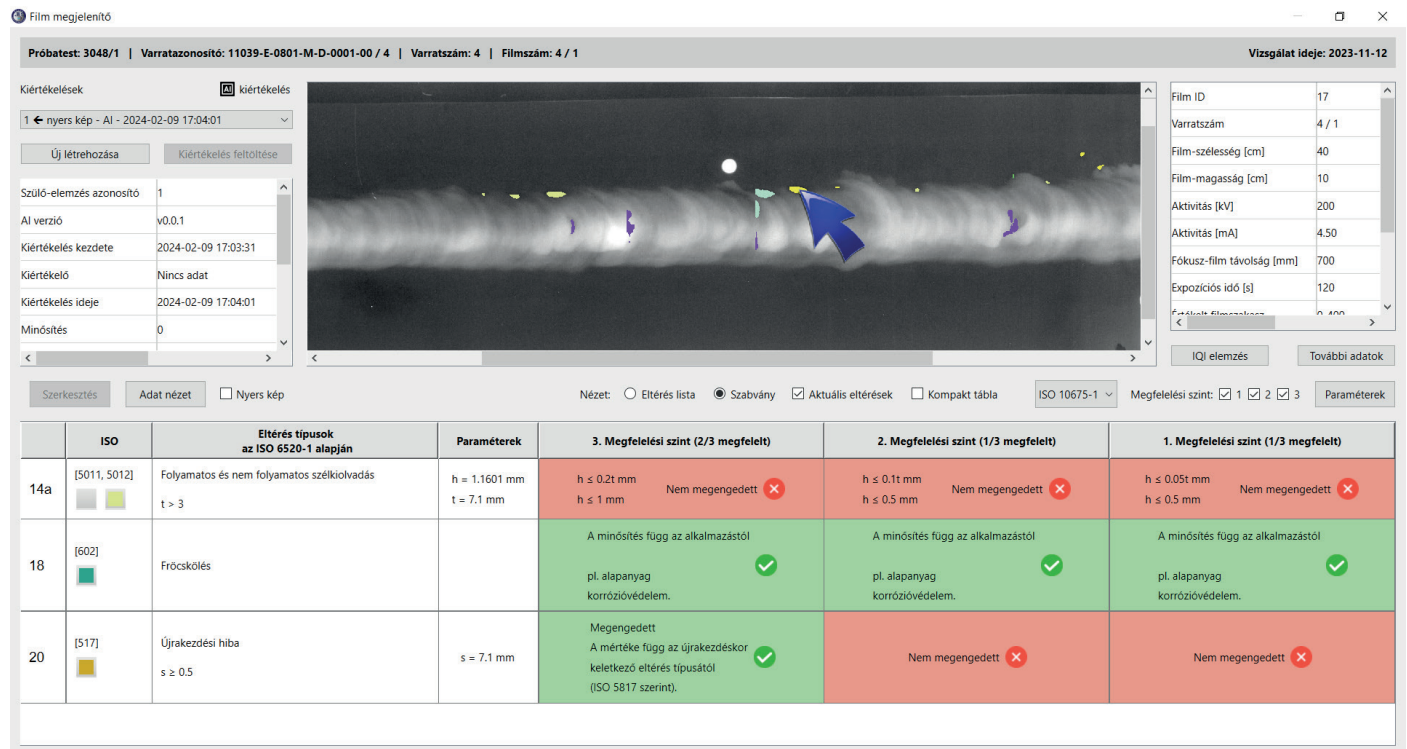
A szerkesztő ablakból való kilépést követően a módosítások automatikusan szinkronizálásra kerülnek a röntgenfilm ablak (ld. 2. ábra) megjelenítővel.

### 3.3 Szabvány szerinti kiértékelés

A szabvány szerinti kiértékelés indításához az alkalmazásban a *Szabvány* jelölő gomb bekapcsolása szükséges. A szabvány típusa egy lenyíló listából választható ki. A képelemző és kiértékelő alkalmazásban jelenleg elérhető



5. ábra: Film szerkesztő modul



6. ábra: Szabvány szerinti kiértékelés, eredmények

szabványok az alábbiak:

- MSZ EN ISO 10675-1:2022 Hegesztett kötések roncsolásmentes vizsgálata. Radiográfiai vizsgálatok átviteli szintjei, 1. rész: Acél, nikkel, titán és ötvözeteik.
- MSZ EN ISO 10675-2:2022 Hegesztett kötések roncsolásmentes vizsgálata. Radiográfiai vizsgálatok átviteli szintjei, 2. rész: Alumínium és ötvözetek.
- MSZ EN ISO 10893-6:2020 Acélcsővek roncsolásmentes vizsgálata, 6. rész: hegesztett acélcsővek varratának radiográfiai vizsgálata az anyaghiányok kimutatására.

Az eltérések szabványos kiértékelése az alkalmazásban teljeskörű és automatikus. A szabvány által előírt eredmények listanézetben jeleníthetők meg (ld. 6. ábra) és tartalmuk mindig frissítésre kerül a röntgenfilm szerkesztése után. A kiértékelésnek két kimenete van, ahogy azt a szabvány is definiálja: „Megengedett” és „Nem megengedett”, melyek az alkalmazásban zöld és piros színnel kerülnek jelölésre. A szabvány által meghatározott 1-2-3 megfelelési szintek a szoftverben jelölőnégyzet segítségével ki-be kapcsolhatóak, ahol értelemszerűen az 1. szint a legszigorúbb szint.

A kiértékelés során kapott eltérési lista (mely a szabvány által előírt összes eltérést listázza) az *Aktuális eltérések*re kattintva a röntgenfilm felvételen megjelenő, aktuális eltérésekre frissül.

A *Kompakt tábla* nézet gomb szabvány módban érhető el és egy kompakt, jól átlátható nézetet biztosít a kiértékelt szabvány eredményeiről.

A *Nyers kép* jelölőnégyzet bepipálásával az eltérések nélküli, eredeti röntgenkép jeleníthető meg.

A *Paraméter* gombra történő kattintással egy új ablakban

a szabvány által használt paraméterlista tűnik fel, külön jelölve az értékelés során a LIMS rendszerből érkező vagy a mesterséges intelligencia révén kapott paramétereket.

Az *Adat nézetben* nagy méretben tekinthetők meg a szabványos kiértékelés eredményei, melyek az értékelés után a LIMS rendszerbe töltődnek fel.

### 3.4 Tanítómodul

A mesterséges intelligencia által előzetesen kiértékelt képek a felhasználók (supervisorok, anyagvizsgáló szakemberek) esetleges javításai (manuális korrekciói) alapján új értékeket kapnak. Ezek alkotják az új tanítóadatokat a rendszerben. A korrigált képek a LIMS rendszeren keresztül kerülnek be a tanító adatbázisba. Ezáltal a rendszer a növekvő adatmennyiségnek köszönhetően tovább tanul és a képek automatikus kiértékelése tovább fejlődik.

Az alkalmazás a külső forrásból érkező, manuálisan hozzáadott képi adatokból származó tanítást is kezeli. Ekkor az alkalmazás tanító algoritmusára újabb képi adat hozzáadásával tovább bővíthető, tanítható. Ezt külön funkció biztosítja a képelemző szoftverben.

## 4. Konklúzió

Mind a hatékonyság, mind a megbízhatóság növelése érdekében kifejlesztésre és most bemutatásra kerülő, mesterséges intelligenciát alkalmazó képelemző és kiértékelő szoftver jelen fókuszja a röntgenképek kiértékelésére érvényes eljárások során gyűjtött adatokon van, mellyel egyedi és speciális tudásbázis létrehozása a cél. A szoftver használatával a tudásbázis egyre bővül, mely által az automatikus kiértékelések egyre pontosabbá és

gyorsabbá válnak.

Az alkalmazás szakemberek által jóváhagyott eredmények mellett gyors, hatékony és automatizált képelemzés és kiértékelés végrehajtására képes. A kiértékelésben résztvevő szabványok köre tovább bővíthető. A szoftver nemcsak röntgenképek, hanem egyéb forrásból származó, pl. mikroszkópi felvételek elemzésére is adaptálható, ami további fejlesztéseket kíván meg az ezt támogató mesterséges intelligencia és szabványos kiértékelés tekintetében.

Elmondhatjuk, hogy az élet minden területén rohamosan egyre nagyobb teret kapó MI technológia immár az anyagvizsgálat területén is új korszakot nyit, melynek egy sikeres úttörő példája a kifejlesztett képelemző és kiértékelő alkalmazás. A szoftver lehetőséget teremtett arra, hogy a nagyméretű ipari létesítmények építés-szerelési, üzemeltetési- és karbantartási tevékenységéhez megbízható, gyors és hatékony támogatást nyújtson.

### Köszönetnyilvánítás

Az AKH- KomplexInno II.– 002/2022–029 számú projekt a Kulturális és Innovációs Minisztérium Nemzeti Kutatási Fejlesztési és Innovációs Alapból nyújtott támogatásával, a 2021-1.1.2-AKH pályázati program finanszírozásában valósult meg.

### Irodalomjegyzék

- [1] MSZ EN ISO 6520-1:2007 Hegesztés és rokon eljárások. Fémek geometriai eltéréseinek besorolása.
- [2] O. Ronneberger, P. Fischer and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in International Conference on Medical image computing and computer-assisted intervention. Springer, 2015, pp. 234–241.
- [3] Jing Xu, Yu Pan, Xinglin Pan, Steven Hoi, Zhang Yi and Zenglin Xu, "RegNet: Self-Regulated Network for Image Classification", IEEE Xplore, Volume: 34, Issue: 11, 2023.
- [4] Xian Zhong, Oubo Gong, Wenxin Huang, Jingling Yuan, Bo Ma, Ryan Wen Liu, "Multi-scale Residual Network for Image Classification", ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2020.
- [5] Kaiming He; Xiangyu Zhang, Shaoqing Ren, Jian Sun, „Deep Residual Learning for Image Recognition” Conference: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), (2016)
- [6] MSZ EN ISO 10675-1:2022 Hegesztett kötések roncsolásmentes vizsgálata. Radiográfiai vizsgálatok átviteli szintjei, 1. rész: Acél, nikkal, titán és ötvözetek.
- [7] MSZ EN ISO 10675-2:2022 Hegesztett kötések roncsolásmentes vizsgálata. Radiográfiai vizsgálatok átviteli szintjei, 2. rész: Alumínium és ötvözetek.
- [8] MSZ EN ISO 10893-6:2020 Acélcsővek roncsolásmentes vizsgálata, 6. rész: hegesztett acélcsővek varratának radiográfiai vizsgálata az anyaghiányok kimutatására.



**ANYAGVIZSGÁLOK LAPJA**  
**PUBLIKÁLJON NÁLUNK!**

**Írjon szakmai vagy általános  
témájú cikket**

az

**Anyagvizsgálók Lapjába!**

Részletekért látogassza meg honlapunkat,  
vagy írjon az alábbi email címek valamelyikére:

[info@anyagvizsgaloklapja.hu](mailto:info@anyagvizsgaloklapja.hu)

[avilap.szerk@gmail.com](mailto:avilap.szerk@gmail.com)

[www.avilap.hu](http://www.avilap.hu)

