

**VLADIMIR ALEKSANDROVICH FEDORENKO – KSENIA
OLEGOVNA SOROKINA – PAVEL VITALYEVICH GIVERTS
– HERKE CSONGOR**

Ütőszegnyomok digitális képeinek osztályozása konvolúciós neurális hálózat útján

Absztrakt

A kriminalisztikailag jelentős nyomok – így az ütőszegnyomok – digitális képeit tartalmazó adatbázisokban végzett automatikus ellenőrzések/összevetések hatékonyságának növelése mesterséges intelligencia algoritmusok alkalmazásával rendkívül időszerű kérdés. A tanulmány célja a konvolúciós neurális hálózatok (CNN) alkalmazási hatékonyságának vizsgálata az ütőszegnyomok képeinek fegyverpéldányok szerinti osztályozásában, egy regionális hüvelyadatbázis keretei között.

A cikk tudományos újdonsága abban merül ki, hogy az ütőszegnyomok képeinek osztályozási pontosságát nemcsak egyetlen kimeneti neuron maximális kimeneti jelének (aktivációjának) alapján vizsgáltuk, hanem a három kimeneti neuronon mért legnagyobb kimeneti jelek figyelembevételével is. Továbbá elemeztük a hibás előrejelzések számát attól függően, hogy az osztályozás az egy, két, illetve három legnagyobb kimeneti jelű kimeneti neuron alapján történt.

Megmutattuk, hogy a pontossági mutató szerint az egyetlen kimeneti neuron maximális jelén alapuló előrejelzési pontosság a 81–87%, míg a három kimeneti neuron legnagyobb jelének figyelembevételével számított pontosság a 91–94% tartományba esik. A CNN betanítása és az osztályozás olyan ütőszegnyom-képmintán történt, amely 41 osztályt tartalmazott. A 41. osztály ismeretlen, az első negyven osztályba (fegyverpéldányba) nem tartozó nyomok képeit foglalta magába.

A munka érdeklődésre tarthat számot a lőfegyver azonosítására specializálódott ballisztikai szakértők, valamint a mesterséges intelligencia algoritmusokat alkalmazó ballisztikai azonosítórendszerek fejlesztői számára.

Kulcsszavak

ütőszegnyomok digitális képei; konvolúciós neurális hálózatok; adataugmentáció, fegyverazonosítás

Abstract

Increasing the efficiency of automated checks and comparisons performed in databases containing digital images of forensically significant traces—such as firing pin impressions—through the application of artificial intelligence algorithms is a highly topical issue. The aim of this study is to examine the effectiveness of applying convolutional neural networks (CNNs) in the classification of firing pin impression images according to individual firearms, within the framework of a regional cartridge case database.

The scientific novelty of the paper lies in the fact that the classification accuracy of firing pin impression images was investigated not only based on the maximum output signal (activation) of a single output neuron, but also by taking into account the largest output signals measured across the three output neurons. Furthermore, we analyzed the number of erroneous predictions depending on whether the classification was based on one, two, or three output neurons with the highest output signals.

We showed that, according to the accuracy metric, the prediction accuracy based on the maximum signal of a single output neuron falls within the range of 81–87%, while the accuracy calculated by considering the highest signal of the three output neurons falls within the 91–94% range. The training and classification of the CNN were performed on a firing pin impression image sample containing 41 classes. The 41st class encompassed images of unknown traces not belonging to the first forty classes (firearm specimens).

This work may be of interest to ballistic experts specialized in firearm identification, as well as developers of ballistic identification systems utilizing artificial intelligence algorithms.

Keywords: digital images of firing pin impressions; convolutional neural networks; data augmentation, firearm identification

Bevezetés

A lőfegyverek azonosítása a kilőtt hüvelyeken található nyomok alapján a legfontosabb igazságügyi ballisztikai szakértői vizsgálatok közé tartozik. Eredményei alapját képezhetik a lőfegyver alkalmazásával összefüggő büntetőügy bizonyítási rendszerének¹. Az azonosítási vizsgálatok egyik típusa a hüvelytárban vagy az ütőszegnyomok digitális képeit tartalmazó adatbázisban végzett ellenőrzés/összevetés, amelyet regionális szakértői-kriminalisztikai központok vezetnek. Az ilyen ellenőrzéseket rendszerint különféle automatizált ballisztikai azonosítórendszerekkel végzik, például „*POISC*”, „*ТАИС*”, „*Арсенал*”.² Ezek segítségével a kilőtt hüvelyeket beszkennelik, és létrehozzák az ütőszegnyomok digitális képadatbázisait.

Ugyanakkor az ilyen rendszerekkel végzett automatikus keresés/összevetés hibákat és tévesztéseket enged meg, mivel a nyomképek összehasonlító algoritmusai korrelációs módszereken alapulnak. Ezért gyakorlati szempontból érdekes a gépi tanulási modellek adaptálása az ütőszegnyomok digitális képei alapján végzett ellenőrzésekhez, valamint az osztályozás hatékonyságának értékelése.

Ismert, hogy képek elemzésében és osztályozásában a legjobb eredményeket a konvolúciós neurális hálózatok (Convolutional Neural Network,

¹ Dil'din Ju. M., Martynov V. V. (2010). Типовые экспертные методы исследования вещественных доказательств. Часть 1. Москва: Е'КC MVD Rossii.

² Automatizált ballisztikai azonosító rendszer, Kompaniya RAME'K.

Forrás: <https://www.ramec.ru/otraslevyie-resheniya/resheniya-dlya-silovyix-struktur/avtomatizirovannaya-ballisticheskaya-identifikatsionnayasistema.html>

Letöltés ideje: 2026.04.13.

CNN) adják³. A CNN egy olyan mélytanulási modell, amely képekből automatikusan jellemzőket (feature) nyer ki, különösen jól kezeli a mintázatokot és textúrákat. Ezért jól hasznosíthatók az arcfelismerésben, az orvosi képfeldolgozásban, de a kriminalisztikai képelemzésben (így az ütőszegnyomoknál) is⁴.

Ezért aktuális feladat egy olyan, CNN-alapú osztályozó fejlesztésének és alkalmazhatóságának vizsgálata, amely az ütőszegnyomok képeit fegyverpéldányok szerint képes osztályokba sorolni. A jelen munka célja annak felmérése, hogy egy konvolúciós neurális hálózat milyen pontossággal képes az ütőszegnyomok képeit fegyverpéldányok szerint osztályozni **olyan** feltételek mellett, hogy az egyes osztályok csak néhány eredeti ütőszegnyomképet tartalmaznak.


Az ütőszegnyomképek automatikus összehasonlításának problémái

Az ütőszegnyomok képeinek fegyverpéldányok szerinti hatékony automatikus osztályozására szolgáló algoritmus kidolgozása összetett műszaki feladat. Ennek elsődleges oka a felületi mikroegyenetlenségek rendkívül nagy változatossága az ütőszeg felületén, amelyek a nyomokban megjelennek⁵. Az 1. számú ábrán példaként több ütőszegnyom képe látható különböző, domináns egyedi (individualizáló) jellegű ismertetőjegy-típusokkal.

³ Forsajt D. A., Pons D. (2018). *Компьютерное зрение: современный подход*. [Számítógépes látás, modern megközelítés.] Moszkva: Vil'yams, 960. o.

⁴ Fedorenko V. A., Sorokina K. O., Giverts P. V.. Многогрупповая классификация следов бойков с помощью полносвязной нейронной сети. [Ütőcsapnyomok többcsoportos osztályozása teljes kapcsolású neurális hálózat segítségével.] *Informacionnye tekhnologii i vychislitel'nye sistemy*. 2022. 115-120. o.
doi: 10.14357/20718632220305.

⁵ Fedorenko V. A., Sorokina K. O., Giverts P. V. (2022). i.m. 115-120. o.



1. számú ábra

Ütőszegnyomok képei különböző domináns egyedi ismertetőjegy-típusokkal


- a) markáns, kompakt alakú inhomogenitások halmaza;
- b) különböző méretű és konfigurációjú inhomogenitások kaotikus halmaza;
- c) eltérő szélességű durva húzások/karcnyomok együttese;
- d) körök;
- e) viszonylag homogén felület gyengén kifejezett sajátosságokkal;
- f) egyetlen nagy, tetszőleges alakú inhomogenitás.

Ezentúl sok ütőszegnyom kevert jellegtípusú ismertetőjegyeket mutat: például egyszerre vannak jelen kör alakú jellegzetességek és meghatározatlan alakú foltok. Emiatt nehéz egységes algoritmust alkotni az ütőszegnyomképek egységes szegmentálására és összehasonlítására.

A vizsgált ütőszegnyomok képeinek hasonlósági értékelését kedvezőtlenül befolyásolja az egyedi ismertetőjegyek megjelenésének variabilitása a nyomokban, amely két fő tényezőre vezethető vissza:

- a csappantyú felületén meglévő különböző típusú inhomogenitásokra;
- az eltérő lövési körülményekre.

A 2. számú ábra a csappantyúfelület azon főbb inhomogenitás-típusait mutatja, amelyek jelentősen növelhetik az ütőszegnyomok változékonyságát⁶.



2. számú ábra

A csappantyúfelület főbb inhomogenitás-típusai

- a) a csappantyúfólia hengerlésének nyomai a felületen és az ütőszegnyomban;
- b) barázdák, karcok;
- c) dombornyomott csappantyújelölés lenyomata ütőszegnyommal;
- d) oxidációs foltok dombornyomott jelölés töredékével együtt;
- e) régi csappantyúk felületi eróziójából származó üregek (kavernák).

Ide sorolhatók többek között: a csappantyúfólia hengerlésének nyomai párhuzamos barázdák formájában; a régi csappantyúk felületi eróziójából származó üregek (kaverna jellegű bemélyedések); a csappantyúk dombornyomott (térbeli) jelöléseinek lenyomatai; oxidációs foltok stb. Az ilyen inhomogenitások részben leképeződhetnek az ütőszegnyomban, ami automatikusan a nyomok variabilitásához vezet.

A lövési körülményekből eredő ismertetőjegy-változékonyságot a gyakorlatban nagyon nehéz figyelembe venni. Ilyen körülmények lehetnek: a csappantyúkeverék működésének variabilitása; a lőporadagolás (töltet)

⁶ Fedorenko V. A., Gvozdkov S. N., Grabovets E. E. (2018). Влияние неоднородностей поверхности капсюлей на вариативность статических следов бойков. [A kupakok felületének inhomogenitásának hatása a statikus ütőcsapnyomok variabilitására.] *Izv. Saratov Univ. (N.S.), Ser. Economics. Management. Law*, 18(2) 202-207. o.
doi: 10.18500/1994-2540-2018-18-2-202-207.

pontatlanságai; a csappantyúfólia eltérő mechanikai tulajdonságai stb. Végül soron ezek a tényezők mind az ütőszeg felületi egyenetlenségeinek változékony megjelenéséhez vezetnek a kilőtt hüvelyeken keletkező nyomokban.

Ütőszegnyomképek összehasonlítása neurális hálózatokkal

Az utóbbi időben több kísérlet történt a gépi tanulási módszerek alkalmazására az ütőszegnyomképek többosztályos besorolásában⁷. Az ezen munkákban használt gépi tanulási módszerek egyik lényeges hátránya, hogy az előkészítő szakaszban az operátornak meg kell határoznia, milyen típusú egyedi ismertetőjegyeket kell az algoritmusnak „megtanulnia” kiemelni a különböző objektumok későbbi összehasonlításához⁸. Ez azonban több okból is problémás:

- egyrészt nem mindig lehet egyértelműen elkülöníteni az ütőszeg felületi mikroreliefje által létrehozott domináns jellegzetességeket a csappantyúfelület térbeli inhomogenitásainak háttérétől;
- másrészt – mint említettük – sok nyom kevert jellegű ismertetőjegyekkel bír;
- harmadrészt az operátor részvétele szubjektív tényezőt visz a jellemzők kijelölésének folyamatába.

A hagyományos gépi tanulási módszerekhez képest a neurális hálózatnak több előnye van. A tanítás során önállóan megtanulja azokat a jegyeket kiemelni, amelyek az egyes osztályokat (nem pedig az oktatóminta egyes objektumait) individualizálják. Ezt követően a hálózat a vizsgált objektum

⁷ Riva F., Champod C.: Automatic comparison and evaluation of impressions left by a firearm on fired cartridge cases. J Forensic Sci. 2014/3. 637-647. o.
doi: 10.1111/1556-4029.12382.

⁸ Wen Z., Curran J. M., Harbison S., Wevers G. E.: Classification of firing pin impressions using HOG-SVM. J Forensic Sci.. 2023. 1946-1957. o.
<https://doi.org/10.1111/1556-4029.15377>

jellemzőit az egyes osztályokra jellemző jegyekkel veti össze. Ez kedve- zően különbözteti meg a neurális hálózatos többosztályos besorolási algo- ritmust olyan más gépi tanulási megoldásoktól, mint például a „Random Forest” (véletlen erdő), a „k legközelebbi szomszéd” (k-NN) stb. Ezért ja- vasolták neurális hálózatok használatát az ütőszegnyomok digitális képei alapján történő automatikus kereséshez/ellenőrzéshez⁹.

Egy, 30 osztályt tartalmazó ütőszegnyomkép-adatbázison végzett vizs- gálat a teljesen összekapcsolt neurális hálózatok (Fully Connected Neural Network, FCNN/Multi-Layer Perceptron, MLP) alkalmazhatóságát ele- mezte, és azt mutatta, hogy az egyetlen kimeneti neuron alapján számított előrejelzési pontosság eléri a 85%-ot¹⁰. A pontosság további növelését kor- látozta a képek kis mérete (75×75 px), valamint a szemantikai rés, amely abból adódik, hogy az eredeti képeket a teljesen összekapcsolt hálózat be- menetén paramétervektorra alakítják. Ezért célszerűbbnek tűnik konvolú- ciós neurális hálózatokat (CNN) alkalmazni, amelyek kifejezetten képek elemzésére és összehasonlítására alkalmasak.

Egy másik kutatás során az ütőszegnyomképek bináris osztályozásának lehetőségét vizsgálták színi neurális hálózattal, amely két azonos felépí- tésű konvolúciós neurális hálózatot tartalmaz¹¹. A modell tanításához és validálásához olyan ütőszegnyomkép-gyűjteményt állítottak össze, ame- lyet 300 fegyverpéldányból kilőtt hüvelyek fenékrészének beszkenyelésé- vel nyertek. A minta tartalmazta az eredeti nyomképeket, valamint azok augmentált („klón”) másolatait, amelyeket az eredeti képek különböző szö- gekkel történő elforgatásával hoztak létre. Az előrejelzési pontosság 87–

⁹ Kamaruddin S. B. A., Ghanib N. A. M., Liong C.-Y., & Jemain A. A.: Firearm Classifi- cation using Neural Networks on Ring of Firing Pin Impression Images. ADCAIJ: Ad- vances in Distributed Computing and Artificial Intelligence Journal, 2013/3. szám. 27-34. o.

doi: 10.14201/ADCAIJ20121312734.

¹⁰ Fedorenko V. A., Sorokina K. O., Giverts P. V. (2022) i.m. 115-120. o.

¹¹ Giverts P., Sorokina K., Fedorenko V.: Examination of the possibility to use Siamese networks for the comparison of firing pin marks. J Forensic Sci. 2022. 2416-2424. o. doi: 10.1111/1556-4029.15143.

88% között volt. Mivel a szíami konvolúciós háló modellje bináris, nem pedig többosztályos besorolásra készült, ezért a jelen munkában a továbbiakban nem foglalkozunk vele.

Egy harmadik munka során osztályozóként egy standard konvolúciós neurális hálózatot használtak, amely 6 konvolúciós rétegből és 1 teljesen összekapcsolt rétegből állt, amit softmax függvény (réteg) és egy osztályozó réteg követett¹². A CNN tanítását és az ezt követő osztályozást 40 osztályon végezték. Az osztályozási pontosság a 86–91% közötti tartományban mozgott. Ugyanakkor ennek a munkának több hiányossága is volt:

- Nem értékelték a minta keresztvalidációjának hatását az osztályozási pontosságra (vagyis azt, hogy a kiinduló adathalmaz „szerencsés” felosztása tanító és teszt részre hogyan befolyásolja a pontosságot). A számítások egyetlen validációra készültek.
- Nem határozták meg a negatív előrejelzések pontosságát és megbízhatóságát, mivel a tesztmintában csak olyan objektumok szerepeltek, amelyek a hálózat által tanult osztályokba tartoztak.
- Nem vizsgálták a modell pontosságát abban az esetben, ha sikernek azt tekintjük, hogy a helyes osztály megjelenik a három legnagyobb kimeneti jelű kimeneti neuron valamelyikén.

Ezen kérdések tisztázására úgy döntöttek, hogy a vizsgálatot konvolúciós neurális hálózattal folytatják. Az új CNN 4 konvolúciós réteget tartalmazott, a konvolúciós magok mérete rendre 5×5 (32), 3×3 (64), 3×3 (128) és 3×3 (256) volt. Az algoritmust Python programozási környezetben valósították meg.

¹² Fedorenko V. A., Sorokina K. O., Giverts P. V.: Классификация следов бойков по экземплярам оружия сверточной нейронной сетью. [Az ütőcsapnyomok osztályozása konvolúciós neurális hálózat segítségével.] Informacionnye tehnologii i vychislitel'nye sistemy. 2024. 87-96. o.
doi: 10.14357/20718632240109

A vizsgált minták előfeldolgozása

A konvolúciós neurális háló hatékony tanításának egyik komoly problémája, hogy osztályonként nagyszámú objektumot tartalmazó tanítómintát kell kialakítani. A gyakorlatban ritkán őriznek 3–5-nél több, ugyanabból a fegyverpéldányból kilőtt hüvelyt. Ezért egy osztály rendszerint legfeljebb 3–5 azonos ütőszeghez tartozó nyomképet tartalmaz.


A neurális háló tanítása előtt az eredeti tanítómintát augmentálták: az eredeti képeket különböző szögekkel, $\pm 90^\circ$ tartományban elforgatták, továbbá véletlenszerűen eltolást alkalmaztak az X és Y tengely mentén ± 15 px tartományban¹³. Ennek eredményeként minden osztály 60 ütőszegnyomképet tartalmazott az adott fegyverpéldányhoz, amelyek közül az eredeti képek száma 4 és 10 között volt. Ezenfelül létrehoztak egy 41. osztályt is 60 olyan nyomképpel, amelyek ismeretlenek, nem ismétlődnek (nem tartoznak ugyanahhoz a már szereplő osztályhoz), és nem sorolhatók az első 40 osztály egyikébe sem. A 41. osztály képei így ismeretlennek tekinthetők az első 40 osztályhoz képest (a továbbiakban ezért a 41. osztályt az ismeretlen képek osztályának tekintjük).

A kiinduló adatbázist három, megközelítőleg egyenlő részre osztották. Az egyik részt tesztmintának tekintették, a másik két rész képezte a tanítómintát, amelyet augmentáltak. Ezután egy másik részt választottak tesztmintának, a fennmaradó részek pedig új tanítómintát adtak, amelyet szintén augmentáltak. Így három, egymástól független tanító-teszt mintakészlet jött létre. A tesztminta képein nem végeztek semmilyen átalakítást. Az ütőszegnyomképek mérete 128×128 px volt; összesen mintegy 300 hüvelyt szkenneltek be.

¹³ Fedorenko V. A., Sorokina K. O., Giverts P. V. (2024): i.m. 87-96. o.

A CNN tanítása és tesztelése osztályozáskor a kimeneti neuron maximális jelének figyelembevételével

A betanított CNN tesztelésének eredményei alapján konfúziós mátrixot állítottak elő, amely a tesztminta osztályozási eredményeit szemlélteti (3a ábra). Emellett elkészítették a kimeneti neuronokon mért maximális jelértékek hisztogramját (3b ábra), amelyek a tesztminta futtatása során az adott előrejelzések alapjául szolgáltak¹⁴.



3a-3b számú ábra

Konfúziós mátrix; A kimeneti neuronokon mért maximális jelértékek hisztogramja

A program megadta a kimeneti neuronok maximális jelének átlagértékeit a helyes és a téves előrejelzések esetén. A helyes előrejelzéseknél a maximális jelértékek $0,9 \pm 0,05$ tartományban voltak, míg a téves előrejelzéseknél $0,70 \pm 0,1$ tartományban.

Ezenfelül egy táblázatot is létrehoztak, amelyben a tesztminta minden objektumához rögzítették az összes kimeneti neuron kimeneti jelét. Ez lehetővé tette az osztályozást az 1., 2. és 3. legnagyobb kimeneti jelű neuron figyelembevételével is.

¹⁴ Fedorenko V. A., Sorokina K. O., Giverts P. V. (2024): i.m. 87-96. o.

A számítások szerint az egész, 41 osztályt tartalmazó adatbázison az összpontosság körülbelül 81–87%. Ha az osztályozást csak az első 40 osztályra végezzük, akkor a pontosság különböző validációk mellett körülbelül 85–91%.

A hibák elemzése a következőket mutatja:

- Egyrészt a téves előrejelzések csaknem fele a 41. (ismeretlen) osztály meghatározásával függ össze (3a).
- Másrészt a téves negatív előrejelzés valószínűsége igen kicsi: 3 validáción végrehajtott 12 futtatásból mindössze 5 ilyen hiba történt, ami az összes előrejelzés kevesebb mint 1%-a.
- Harmadrészt a „ismert” osztályok közötti összetévesztés (például a 7. osztályba tartozó objektum 32. osztályba sorolása) ténylegesen a II. típusú hiba (téves negatív) kialakulásával tekinthető egyenértékűnek. Valóban: a szakértő észlelheti az osztályozási hibát, de nem fog manuálisan ellenőrzést végezni az egész adatbázison, ha az legalább 200–300 osztályt tartalmaz. Ezért az ilyen nyomot az ismeretlen nyomok osztályába sorolják, vagy kiegészítő vizsgálatra küldik.

Sikernek tekinthető, ha a helyes osztály szerepel a három legnagyobb kimeneti jelű kimeneti neuron egyikén. Ilyenkor a szakértő számára nem jelent nehézséget a vizsgált kép összehasonlítása a modell által kijelölt három osztály nyomképeivel. A három neuronos osztályozási pontosság értékeléséhez a CNN teszteredményei alapján táblázatot készítettek a kimeneti neuronok sorszámaival és az A1, A2, A3 értékekkel (az 1., 2. és 3. legnagyobb kimeneti jel). Az 1. táblázat a kizárólag az A1 maximális jel figyelembevételével, illetve az A1, A2, A3 három legnagyobb jel figyelembevételével számított pontossági eredményeket mutatja. A táblázatból

látható, hogy a három neuronos osztályozás esetén az összes pontosság átlagértéke mintegy 10%-kal nőtt¹⁵.

Csak A1 tanítás						
1. validáció	%	2. validáció	%	3. validáció	%	átlag
Pontosság (összes)	80.1	Pontosság (összes)	85.2	Pontosság (összes)	82.7	82.6
Pontosság (40) 2. típusú hiba	88	Pontosság (40) 2. típusú hiba	89	Pontosság (40) 2. típusú hiba	88	88.3
Pontosság (41) 1. típusú hiba	50	Pontosság (41) 1. típusú hiba	70	Pontosság (41) 1. típusú hiba	62.5	60.8
A1+A2+A3 tanítás						
Pontosság (összes)	93.1	Pontosság (összes)	94	Pontosság (összes)	91.4	92.8
Pontosság (40) 2. típusú hiba	96.7	Pontosság (40) 2. típusú hiba	95.6	Pontosság (40) 2. típusú hiba	95.6	95.9
Pontosság (41) 1. típusú hiba	75	Pontosság (41) 1. típusú hiba	87.5	Pontosság (41) 1. típusú hiba	75	79.1

1. számú táblázat
Az osztályozási pontosság vizsgálata az A1,
valamint az A1 + A2 + A3 kombináció alkalmazása esetén

Elemezték a hibák csökkenését a második és harmadik legnagyobb jel figyelembevételével. Megállapították, hogy az A2 és A3 figyelembevétele átlagosan a felére csökkenti a hibák számát. A téves előrejelzések domináns csökkenése az A2 (második legnagyobb) jel figyelembevételének köszönhető, különösen az első 40 osztályhoz tartozó objektumok osztályozásánál. A 41. osztály hibáinak csökkenése az A2 és A3 figyelembevételével nem ilyen jelentős. Ez arra utal, hogy a 41. osztályhoz kapcsolódó hibák csökkentéséhez érdemben bővíteni kell az osztály ismertetőjegy-diverzitását több, különböző osztályból származó, eltérő jegytípusú objektum bevonásával.

¹⁵ Fedorenko V. A., Sorokina K. O., Giverts P. V. (2024): i.m. 87-96. o.

Következtetések

A pontossági mutató alapján az egyetlen, maximális jelű kimeneti neuronra épülő osztályozás pontossága 81–87% között alakul. Ugyanakkor a kimeneti neuronok három legnagyobb jelének együttes figyelembevétele jelentős javulást eredményez a teljesítményben. Az egész, a 41. (ismeretlen) osztályt is magába foglaló adatbázison az átlagos klasszifikációs pontosság 82,6%-ról 92,8%-ra növekszik. Az első 40 osztály esetében – az ismeretlen osztály kizárásával – az átlagos pontosság 88,3%-ról 95,9%-ra emelkedik, míg a 41. osztályon 60,8%-ról 79,1%-ra javul. Összességében tehát megállapítható, hogy a három legnagyobb kimeneti érték figyelembevétele elfogadható osztályozási pontosságot biztosít, ugyanakkor további kutatások szükségesek, különösen a 41. osztályhoz kapcsolódó hibák csökkentése érdekében.

Az ilyen típusú osztályozási algoritmusok jól alkalmazhatók az ütőszegnyomképek adatbázisaiban végzett automatikus ellenőrzések és összevetések során. Ugyanakkor a kriminalisztikai szakirodalomban jelenleg is vita tárgyát képezi a mesterséges intelligencia segítségével nyert bizonyítékok elfogadhatósága. Ezen bizonyítékok értékelése több kulcstényezőtől függ, így különösen a relevanciától, a megbízhatóságtól és a hitelességtől¹⁶. Emellett kiemelt jelentőségű az is, hogy a mesterséges intelligencia alapú rendszer működése – legalább általános szinten – magyarázható legyen a döntéshozó számára, vagyis érthetővé váljon, hogyan jut a rendszer az eredményeihez¹⁷.

¹⁶ Herke Csongor: Automated Fingerprint Identification: The Role of Artificial Intelligence in Crime Scene Investigation. Forensic Sciences Issue 2026/1. 6. o.
doi: 10.3390/forensicsci6010006

¹⁷ Gentry E.: The Challenges of Integrating AI-Generated Evidence Into the Legal System. 2024.

Forrás: <https://www.akerman.com/en/perspectives/the-challenges-of-integrating-ai-generated-evidence-into-the-legal-system.html>

Letöltés ideje: 2026.04.13.

Bár a gépi tanulási modellek hatékonyan képesek feladataik ellátására, gyakran hiányzik belőlük a megfelelő magyarázhatóság, így „fekete dobozként” működnek¹⁸. Ez komoly kihívást jelent az eredményeik közvetlen bizonyítékként történő felhasználásakor. Ugyanakkor a bírósági ballisztikai azonosításban széles körben alkalmazott automatizált rendszerek – mint például a POISC, az IBIS vagy a ТАИC – lényegében hasonló helyzetben vannak. A szakértők a bíróság előtt rendszerint nem részletezik ezen rendszerek működésének pontos mechanizmusait vagy az összehasonlítás során figyelembe vett jellemzőket. Ehelyett a rendszer által kiemelt képi sajátosságok vizsgálata, valamint saját szakértői tapasztalatuk alapján erősítik meg vagy cáfolják az eredményeket.

Ahogy arra a szakirodalom is rámutat, a mesterséges intelligencia nem helyettesíti, hanem kiegészíti a szakértői munkát azáltal, hogy automatizál bizonyos folyamatokat, miközben az emberi kontroll és szakmai megítélés továbbra is kulcsfontosságú marad, különösen a nagy megbízhatóságot igénylő területeken¹⁹. Mindezek alapján valószínűsíthető, hogy a konvolúciós neurális hálózatokon alapuló mélytanulási algoritmusok a jövőben széles körben elterjednek az igazságügyi ballisztikai azonosításban, feltéve, hogy a szakértők kritikai módon értékelik az általuk szolgáltatott eredményeket²⁰.

¹⁸ Billah M.: Explainable AI for Digital Forensics: Ensuring Transparency in Legal Evidence Analysis. J Forensic Sci Res Issue 2025/2. 109-116. o.
doi: 10.29328/journal.jfsr.1001089

¹⁹ Jeffrey C.: Role of AI in Forensic Accounting and Fraud Investigations: Efficiency, Risk and Human Oversight. 2025.

Forrás: <https://www.withum.com/resources/role-of-ai-in-forensic-accounting-and-fraud-investigations-efficiency-risk-and-human-oversight/>
Letöltés ideje: 2026.04.13.

²⁰ A tanulmány a Pécsi Tudományegyetem 001_2025_PTE_RK/5 sz. pályázatának támogatásával készült.