

A mesterséges és emberi intelligencia értéke a csontszcintigráfia példáján keresztül

KOVÁCS ÁKOS¹, LÉGRÁDI GÁBOR¹, WIRTH ANDRÁS¹, NAGY FERENC², FORGÁCS ATTILA², BARNA SÁNDOR², GARAI ILDIKÓ^{2,3}, BÜKKI TAMÁS¹

¹Mediso Medical Imaging Systems Kft., Budapest, ²ScanoMed, Orvosi, Diagnosztikai, Oktató és Kutató Kft., ³Debreceni Egyetem Orvosi Képző és Kísérleti Klinika, Nukleáris Medicina nem Önálló Tanszék, Debrecen

Levelezési cím:

Dr. Bükki Tamás, Mediso Medical Imaging Systems Kft.,
1037 Budapest, Laborc. u. 3. Tel.: +36-30-3751960,
e-mail: tamas.bukki@mediso.com

Közlésre érkezett:

2020. február 5.

Elfogadva:

2020. február 17.

Bemutatjuk a mesterséges intelligencián (MI) alapuló módszerek egy lehetséges klinikai alkalmazását, mely képes a jelentős zajjal terhelt csontszcintigráfias felvételek hatékony zajszűrésére. A speciális MI-alkalmazás az előzetes vizsgálatok alapján lehetővé teszi, hogy számottevően csökkenthessük a vizsgálati időt vagy a betegnek beadott aktivitást, így csökkentheti a beteget, asszisztenst, orvost ért sugárterhelést. Bemutatjuk az MI-szűrő alkalmazása működésének sajátosságait, tanítási folyamatát, melyet fontos érteni ahhoz, hogy a leletező orvos biztonsággal, „másodlagos megbízható véleményként” figyelembe vehesse az MI-feldolgozott képet, és ezáltal pontosabb diagnózist fogalmazhasson meg a segítségével. Kitérünk az algoritmus robusztusságvizsgálatára, valamint a komplex klinikai ellenőrzés sajátosságaira és kihívásaira is. *Magy Onkol* 64:153–158, 2020

Kulcsszavak: mesterséges intelligencia, csontszcintigráfia, klinikai validáció, zajcsökkentés, jel-zaj viszony javítása

We present a possible method of Artificial Intelligence (AI) based applications that can effectively filter noise-sensitive bone scintigraphy images. The use of special AI, based on preliminary examinations, allows us to significantly reduce study time or activity administered to the patient, thus reducing the patient, assistant, and physician radiation. We present the features of the AI filtering application, its teaching process, which is important to understand, so that the physician can safely take the processed image of the AI as a „secondary reliable opinion” to help them make a more accurate diagnosis. We also examine the robustness of the algorithm, the specificities and challenges of complex clinical control.

*Kovács Á, Légrádi G, Wirth A, Nagy F, Forgács A, Barna S, Garai I, Bükki T. The value of artificial and human intelligence – the example of bone scintigraphy. *Magy Onkol* 64:153–158, 2020*

Keywords: artificial intelligence, bone scintigraphy, clinical validation, noise reduction, signal-to-noise improvement

BEVEZETÉS

A tudományos eredményeken alapuló betegközpontú ellátás javítása a mai kor egyik fontos kihívása. Ennek egyik lényeges feltétele, hogy csúcstechnológiákat alkalmazó diagnosztikai berendezéseket érdemes használnunk (1), hiszen a betegségek korai és pontos felismerése nélkülözhetetlen a beteget legjobban segítő terápiás út megválasztásában.

A XXI. század csúcstechnológiáit már nem csupán az igen költséges és nagy érzékenységű diagnosztikai műszerek jelentik. Hasonlóképpen fontosak a diagnosztikát támogató speciális szoftverek, pl. a GPU-kártyákon futó, valós idejű 3D képrekonstrukció (2), valamint pl. a CT- vagy MRI-berendezések anatómiai információit a SPECT vagy PET funkcionális információival fuzionáltan megjelenítő megoldások (3). Emellett egyre inkább nélkülözhetetlenek a leletező orvos döntését közvetlenül segítő alkalmazások, lásd pl. computer-aided diagnosis (CAD) (4).

Ezek a szoftverek egyre több „okosmegoldással” rendelkeznek, melyek pl. lehetővé teszik az egyszerűbb betegpozicionálást, lehetővé teszik, hogy jobb jel-zaj viszonyú képeket kapjunk ugyanolyan vizsgálati feltételek mellett, vagy épp számottevően csökkentjük a vizsgálati időt és/vagy a beteget, asszisztentst, orvost érő kockázatot, pl. jelentősen csökkentve a felhasznált izotóp mennyiségét és így a beteget és az asszisztenseket ért dózist. Mindez természetesen jelentős fajlagos költségcsökkenéssel is jár, mely adott forrás mellett több beteg vizsgálatát is lehetővé teheti.

A XXI. század egyik új technológiáját a mesterséges intelligencián (MI) alapuló megoldások jelentik, melyek az orvosi képalkotásban is egyre nagyobb szerepet játszanak (5). Ezek sajátossága, hogy egy rendelkezésre álló képadatbázis alapján képesek megtanulni, és a megtanultak alapján felismerni és akár értékelni egy kép diagnosztikailag releváns részletét, pl. megkülönböztetni, megszámlálni bizonyos sejteket egy tenyészetben, vagy kiemelni, kontrasztosabbá tenni a patológiás elváltozásokat.

A robbanásszerűen megjelenő, MI-t alkalmazó technológiákat és ezek klinikai értékét igen nehéz követni és megítélni. Tekintve a radiológus megnövekedett felelősségét, aki nem csupán a képet analizálja, hanem véleményez is, érthető, hogy ennek kapcsán több aggodalom is megjelenik. Egyrészt aggodalom attól, hogy az MI-t felhasználó (CAD) rendszerek a leletező orvost előbb-utóbb kiválthatják, hiszen bizonyos esetekben pontosabb diagnózist képesek szolgáltatni (6); másfelől aggodalom attól, hogy mi történik, ha az MI-t alkalmazó algoritmus hibás információt, tippet generál, és így a döntéséért felelősséget vállaló orvos erre támaszkodva több esetben adhat majd hibás diagnózist.

Fontos és megszívlelendő konklúzióra jut egy 2020-as japán tanulmány (6), mely rámutat arra, hogy az MI-algoritmusok által feldolgozott képek, valamint diagnosztikai jelzőszámok (score-ok) csupán egy másodlagos megbízható véleményt adnak a leletező és döntéshozó orvos számára. Így az orvosi gyakorlatban megjelenő MI megoldások sze-

repe, hogy hatékonyan támogassa az orvost a döntésben, és nem váltja ki az orvosi tudását és tapasztalatán alapuló megérzéseit. Épp ezért fontos, hogy az MI-t alkalmazó orvosi szoftvereknél egy, az eddiginél is szigorúbb, az MI megoldások tanulási sajátosságait is figyelembe vevő klinikai kipróbálással kell bizonyítani azok klinikai és diagnosztikai értékét (7).

A jelen tanulmány célja, hogy egy konkrét esetben, az onkológiai diagnosztikában jelentős szerepet játszó csontszcintigráfiában bemutassunk egy új, ígéretes, MI-alapú alkalmazást, mely várhatóan számottevően javíthatja majd a csontszcintigráfia pontosságát és diagnosztikai értékét. Célnk egyben az is, hogy az olvasó egy konkrét példán keresztül megérthesse egy MI-alapú eljárás működésének sajátosságait és klinikai ellenőrzésének szempontjait. Bízunk benne, hogy mindezzel segítjük, hogy az MI megoldások által szolgáltatott információkat valóban a helyén kezelheti majd az orvos felhasználó egy másodlagos megbízható véleményként, és így felelősséggel és bátran használja majd ezeket az új megoldásokat.


MESTERSÉGES INTELLIGENCIA ALAPÚ KÉPSZŰRŐK

A csontszcintigráfias vizsgálatok sokféle indikációval rendelkeznek (8), az ortopédiától a szájsebészetten át az ízületi gyulladások vizsgálatáig, de az egyik legjelentősebb terület az emlő-, tüdő-, prosztata- és egyéb lágyrészdaganatok csontáttéteinek korai kimutatása.

Az eljárás során a betegbe intravénásan injektált difoszfónát- (pl. MDP, HMDP) molekulákat Tc-99m izotóppal jelölik. A csontszövethez kötődő izotóp eloszlását pedig gammakamerával egésztest-vizsgálat során térképezzük fel. A keletkező képek jel-zaj viszonyát alapvetően 6 faktor határozza meg: a beadott aktivitás, az akkumulációs idő, a farmakonkötődés mértéke (függ pl. az életkortól), a leképezés ideje, a kamera gammaérzékenysége, mely utóbbi függ a használt kollimátor érzékenységétől is, valamint a páciens testének gammafoton-elnyelése, mely a jel-zaj viszonyt számottevően rontja.

Sok évtizedes törekvés, hogy olyan zajsűrűvel egészítsük ki a képalkotást, mely a mérés során gyűjtött képek jelentős zaját elnyomja, ugyanakkor a detektálható léziók kontrasztját, láthatóságát szignifikánsan javítja. Valójában ez a feladat igen nagy kihívás, mert a zaj elnyomása, valamint a struktúrák kontrasztjának megtartása egymás ellen dolgozik. Ennek ellenére ismerünk értékes megoldásokat, és kiforrott metodika is rendelkezésünkre áll, hogy eltérő szöveti struktúrákon mérhessük az algoritmusok jóságát (9).

Az MI-alapú zajsűrűk működése és képjellemzői alapvetően eltérnek a hagyományos algoritmusokétól. A mesterséges neurális hálózatok (artificial neural network, ANN) olyan, hagyományos számítógépeken futtatható programok, melyekben idegsejtek összeköttetését, azok hálózatát modellezzük. A mesterséges idegsejtek (melyeket a program modellez) kapcsolatának erősségei, valamint az egyes mesterséges sejtek reakció-küszöbértéke állítható, ezek a hálózat paraméterei. Egy-egy ilyen hálózat jellemzően sok millió paraméterrel rendelkezik. A tanítási folyamat során a há-



1. ÁBRA. Csontszcintigráfiai felvételek, balra a szűretlen, jobbra az MI-szűrővel szűrt párja. a) „Normál” eset, vagyis a standard, klinikai protokollnak megfelelő aktivitással és mérési idővel készült felvétel; b) ehhez képest 1/4 aktivitással, ill. mérési idővel készült (szintetizált) páros; c) 1/32 aktivitással vagy mérési idővel készített eredetiből szintetizált zajos és szűrt változat

lőzatnak képeket mutatunk, úgy, hogy a kép minden egyes pixeléhez egy vagy több neuron is kapcsolódik [10]. A tanítási folyamat során ezeket a paramétereket hangoljuk be.

Esetünkben a tanító és tesztadatbázis képeit csontszcintigráfiai anterior és poszterior egésztest-felvételekből állítjuk össze, és minden felvétel esetén a képet újra-min-tavételeztük binomiális eloszlás alapján, mesterségesen generálva olyan, reálisan felzajosított felvételeket, mintha fele, negyede, nyolcada stb. felvételi idővel vagy beadott aktivitás mellett készültek volna.

A szűrőként használt, speciális topológiájú hálózatunk végül egy képet állít elő. A bemenetre a mesterségesen zajos képeket adjuk, a kimeneten pedig egy simított, kontrasztos képet várunk, hasonló annak alacsony zajtartalmú párjához. A hálózat paramétereit pedig addig hangoljuk, míg ezt a kívánt eredményt nem kapjuk a betanító képadatbázis minden elemét figyelembe véve.

A használt konvolúciós topológiájú (CNN) auto-encoder hálózat [11] a tanítási folyamat során képes azonosítani, megtanulni a csontfelvételeken lévő jellegzetes struktúrákat, pl. bordákat, csigolyákat, ízületeket, valamint a jellegzetes léziókat és más dúsulásokat, pl. az intravénás beadás helyének jellegzetes aktivitáseloszlását. A hálózat a betanítási folyamat során azonosított képszegmensekből, azok mintáiból egy új képet szintetizál, mely legjobban hasonlít az akár jelentős zajjal terhelt bemeneti képhez. A szűrt, azaz szintetizált új kép meghökkentő élességgel, és a szűretlen képhez kvalitatívan viszonyítva számottevően jobb jel-zaj viszonytal rendelkezik. Különösen megdöbbentő az eredmény akkor, ha az aktivitást/mérési időt jelentősen, akár 1/32 részére lecsökkentjük (1. ábra).


Az 1.c ábra kapcsán fontos kitérnünk az MI-algoritmusok egyik jellegzetességére, nevezetesen arra, hogy a mesterséges neurális hálózat képes a zajba egy határozott struktúrát „álmodni”, mely nem feltétlenül van összhangban a valósággal, különösen a zajban teljesen eltűnő, mégis a szűrt képen esetlegesen ábrázolódó halmozódások tekintetében. Épp ezért olyan fontos a szűrők komplex klinikai ellenőrzése, mely során egyben meghatározzuk, hányadrész mérési idő, ill. beadott aktivitás mellett tudunk még megbízni az eredményben (lásd még alább).

AZ MI-SZŰRŐK JELLEGZETESSÉGEI ÉS KLINIKAI ELŐVIZSGÁLATA

Egy MI-alapú algoritmus viselkedését nem csupán maga a neuronok összekötési topológiája határozza meg, hanem e neuronoknak a tanulás során beállított több millió paramétere. A működés ellenőrzése többrétű kell, hogy legyen. A tanuló-adatokból (esetünkben anonimizált klinikai képek) elkülönítünk egy teszt-, ill. validációs adatbázist, melyek nem részei a tanuló-adatoknak. Első körben ezeken ellenőrizzük a szűrés jóságát, azt vizsgálva, mennyire képes helyreállítani az eredeti képet, ill. nem tesz-e fel anatómiai zavaró mintákat a képre. Különösen nagy hangsúlyt fektettünk arra, hogy a szűrő semmiképp ne szintetizáljon léziókat olyan helyekre, ahol nincsenek.

A működés vizsgálatát ezt követően egy robusztussági analízis követte, ahol megvizsgáltuk például, hogy olyan struktúrákat, mint pl. egy katéter, melyet csak kevés felvétel tartalmazott a betanításra szolgáló képek közül, képes-e a hálózat helyesen szintetizálni, lásd pl. a 2. ábrát.

Zajszűrés esetén a lehetséges hibák másik típusa az, amikor egy dúsulás láthatósága romlik el, sőt, drasztikus



2. **ÁBRA.** Balra a mesterségesen 1/8 statisztikára rontott kép, jobbra a szűrt párja. A vizeletkatétert is megfelelően szintetizálja az MI-szűrő

esetben akár el is tűnik a szűrés hatására. Valódi, címkézett, leletezett felvételeken megmérhetjük a hálózatok léziómegtartás szerinti teljesítményét, de a különféle megbetegedéseket tartalmazó képek beszerzése, annotálása nehéz és költséges folyamat (lásd később).

Az egyik megközelítésünk ennek a nehézségnek az enyhítésére szintetikus léziógenerálás segítségével működik. Amennyiben élethű léziókat vagyunk képesek felvinni egészséges területekre, abban az esetben pontosan tisztában lehetünk a lézió elhelyezkedésével és jellegével, így akár már tanítás közben is folyamatosan monitorozhatjuk a neurális hálózat teljesítményét a léziómegtartás tekintetében. Sőt, ez a megoldás rögtön arra a kérdésre is választ adhat, hogy melyik neurális hálózat rendelkezik a jobb zajszűrő képességgel, így rangsorolhatjuk őket.

Általánosságban elmondható, hogy több betanított neurális hálózat megközelítőleg hasonlóan „tetszetős” képminőséget eredményez, viszont előfordulhat, hogy ennek ellenére nagymértékben eltérő diagnosztikai értékkel bírhatnak ezek a megoldások. Így a hálózatok rangsorolására a mesterséges léziógeneráláson alapuló tesztek egy automatikusan alkalmazható mértékként használhatóak a neurális hálózatok értékelésére, orvosok bevonása nélkül. Így az orvosok által tesztelendő (klinikai elővizsgálat, lásd alább) neurális hálózatok száma lecsökkenthető már a fejlesztés korai stádiumában.

A robusztusságvizsgálatot követően orvos kollégák bevonásával (Scanomed Kft., Debrecen) kezdődhetett meg a szűrők klinikai elővizsgálata. Ennek a vizsgálatnak a célja az volt, hogy olyan orvosok, akik sok hasonló képpel dolgoztak, rámutathassanak az esetleges hibákra, műtermékekre, valamint véleményezzék az eszköz használhatóságát.

A ScanoMedben 2019. 08. 01. és 2019. 10. 25. között 412 rutin csontszcintigráfiás egésztest-vizsgálat képi anyagát szűr-

tük meg az itt bemutatott MI-alapú alkalmazással. A betegek rutinszerűen 550–600 MBq ^{99m}Tc -MDP-t kaptak intravénásan, majd 2 óra akkumulációs időt követően készült el az egésztest-felvétel. Amint elkészült a planáris felvétel, a szűrt kép 1-2 percen belül elkészült és segítette az orvosokat a kiegészítő vizsgálatok eldöntésében úgy, hogy ha bármely képen metasztázisra gyanús elváltozást talált, akkor SPECT/CT-t kellett indikálnia. A vizsgálat során úgy tapasztaltuk, hogy az MI-filter új léziót nem generált és nem törölt. Artefaktumot nem hozott létre. Az orvosoknak könnyebb volt lokalizálni az eltéréseket (számolni a bordákat, csigolyákat), eldönteni a kiegészítő vizsgálat szükségességét, és mindez gyorsította magát a leletezést.


A 3. ábrán szeretnénk bemutatni egy esetet, amely az MI-szűrés diagnosztikai értékét jól reprezentálja. Megfigyelhetjük, hogy míg a szűretlen képeken talán a 2018-ban és 2019-ben készült képeken íránk le először a fokális dúsulást a koponyán, addig a szűrt képeken korábbi felvételeken is felvetődött volna. Az MI-szűrt képek segítségével bizonyos dúsulások valószínűleg hamarabb detektálhatóvá válnak, de ezt még követéses vizsgálatokkal szükséges megerősíteni. Érdekes, hogy miután a szűrt felvételen sikerül beazonosítani a halmozódást, az eredeti felvételen is sejthető a halmozódás, mivel tudjuk, hogy hol kell keresni. Új lézió tehát továbbra sem jelent meg, hanem a meglévő lézió detektálhatósága javult.

TERVEZETT KOMPLEX KLINIKAI VIZSGÁLAT ÉS FELHASZNÁLÁSI CÉLTERÜLETEK

A csontszcintigráfiás vizsgálatok érzékenysége magas, a radiofarmakon sajátosságából adódóan viszont specifitása alacsony. Bár a vizsgálatok leggyakoribb indikációja a csontáttétkeresés, ugyanakkor ezeknél a betegeknél sok a degeneratív jellegű dúsulás is, főleg idősebb korban. A tervezett klinikai validációnál fontos figyelembe venni, hogy a tanuló képadatbázis felvételeiben milyen típusú dúsulások fordulnak elő, hogy a klinikai rutinban előforduló jellemző dúsulások egyaránt és jelentős súllyal (akár több 100 kép!) jelen legyenek. Mindez a tanuló- és teszt-, ill. validációs képek gondos válogatását igényli, elkerülve a spektrumeltolódás jelenségét [12]. Épp ezt nehezíti a vizsgálat alacsony specifitása (a differenciáldiagnosztikát a mögöttes struktúra azonosítása jelenti, pl. az elvégzett szövettan vagy morfológiai eltérés alapján). Az MI-szűrők használatát ugyanakkor csak a tanuló adatbázisban jelen lévő és a validáció során megvizsgált dúsulástípusokra szabad engedélyezni.

Tekintve pl., hogy nem tudunk jelenleg a tanuló adatbázis számára biztosítani kellő számú gyermekről készült felvételt, az MI-szűrő algoritmus nem kap elegendő képet ahhoz, hogy pl. a gyermekek gyors csontfejlődése miatt a képeken megjelenő epifízisugák struktúráját biztonsággal megtanulhassa. Ezért egyelőre az MI-szűrők használatát csak felnőttekről készült képek értékeléséhez fogjuk ajánlani.

Itt fontos kitérnünk arra, mi a helyzet az alacsony prevalenciájú betegségekkel. Ha egy betegség prevalenciája alacsony, az nem jelenti ugyanezt a csontszcintigráfiás vizsgálat szempontjából, hiszen erre a vizsgálatra döntően azon betegpopuláció



3. ÁBRA. Szűretlen (fent) anterior egésztest-felvételek, csak a koponya bemutatva, valamint ezek MI-szűrt párja (lent), balról jobbra a felvétel éve, 2015, 2016, 2018 és 2019. A lézió a szűrt képen egyértelműbb módon ábrázolódik

érkezik, akiknek az esélye pl. a csonttátek előfordulására magas, illetve már tudottan van csonttáte, és utánkövetésre érkezik. Tehát a szűrt betegpopuláció, akik egy adott indikációval csontszcintigráfiára érkeznek, a vizsgálat szempontjából már nem alacsony prevalenciájú. Vagyis a klinikai validáció szempontjából az indikációt fontos figyelembe venni.

Épp ezért a klinikai validációt csak adott indikációk, és ezzel asszociálható speciális dúsulások mellett tervezzük elvégezni, olyan típusú esetekre, melyek nagy számban a rendelkezésünkre álltak és melyeken az algoritmus tanult. Fontosnak tartjuk, hogy a nem validált indikációk esetén (ahol speciális dúsulásstruktúrák előfordulhatnak) a lelevező orvost erre figyelmeztessük, hiszen ez befolyásolhatja, mennyire támaszkodhat az MI-feldolgozott képre.

Egy adott indikáció esetén, tekintve, hogy a dúsulások mögötti patológia az esetek nagy részében nem igazolt szövettannal, szembe kell néznünk egy másik nehézséggel is. A prediktív teljesítmény analíziséhez (12) fel kell venni az MI-szűrők receiver operation curve (ROC) görbéit (13), melyek a valódi pozitív diagnózis rátáját ábrázolják a fals pozitív diagnózis ráta függvényében. Ez képes ugyanis egyértelműen megmutatni, hogy az MI-alkalmazás klinikai értéke szignifikáns-e vagy sem, valamint milyen aktivitás-, ill. vizsgálati idő-hányadra mehetünk le biztonsággal, hogy a szűrt kép a diagnózis jóságát és pontosságát még megtartsa. A ROC-görbék felvételéhez azonban nélkülözhetetlen a ground-truth feltárása, azaz a dúsulás mögötti tényleges klinikai ok kiderítése (pl. van-e csonttáte a betegnek vagy nincs). Erre lehetőséget az ad, ha

az egyes felvételeket a beteg kórtörténetét is figyelembe véve elemezzük, bevonva más vizsgálatok eredményét is a döntésbe, illetve a felvételeket egy orvoscsoport értékeli ki (13). Mindez a validáció költségét jelentősen növeli.

Mindemellett szükséges lehet, hogy eltérő klinikai környezetben eltérő képeken tanítsuk be a szűrőt, mert pl. a vizsgált betegek testtömegindexe számottevően eltér a Magyarországon felvett betegekhez képest. Az FDA (U.S. Food & Drug Administration) épp ezért az MI jellegű orvosi szoftverekre speciális verifikációs metodikai ajánlást dolgozott ki (7), melynél fontos, hogy az életciklus alatt folyamatos minőségbiztosítást végezzünk. Ez ugyanakkor egy rendszeresen és szinte folyamatosan futó klinikai értékelést igényel, melynek költsége, tekintve a fenti nehézségeket, akár olyan magas is lehet, hogy ez megakadályozhatja egy megbízható, MI-t felhasználó, klinikailag validált megoldás megjelenését a gyakorlatban (hagyományosan a ROC-görbék felvételéhez több ezer vagy még több beteg komplex orvosi kiértékelése szükséges). Szerencsére ismert olyan kiértékelési megoldás, amely segítségével a klinikai kiértékeléshez használt, orvosilag ellenőrzött esetek száma várhatóan kellően alacsonyan tartható, ugyanakkor a működés folyamatos nyomon követése és kontrollja megoldható (14).

Az előzetes klinikai vizsgálatot követően közösen megvizsgáltuk azt is, milyen területeken lehet értékes a kifejlesztett MI-szűrő alkalmazása, és a következő, egymástól elkülönülő céletterületeket azonosítottuk.

- Segíti a radiológust a lelevezésben: gyorsítja a lelevezést, így anatómiai információt szolgáltatató kép (CT/MR) hiányában

is könnyebben azonosítja az anatómiai struktúrákat az orvos, pl. könnyebben leszámolja a bordákat.

- Várhatóan legalább 1/3-1/4 részére csökkenthető a vizsgálati idő vagy a betegbe beadott aktivitás anélkül, hogy romlana a szűrt kép diagnosztikai értéke.

- A jelenlegi klinikai protokoll szerinti aktivitás és vizsgálati idő mellett a kisebb léziók felismerési rátája várhatóan javul, ill. a bizonytalan léziók száma csökken, így kevesebb esetben lesz szükség további SPECT-vizsgálatra a diagnózis megerősítéséhez.

Ez alapján már meg tudjuk tervezni az MI-szűrők komplex klinikai ellenőrzését, melyhez több hazai és külföldi kórházzal klinikai kipróbálási projektet tervezünk elindítani. Ehhez jelenleg keressük az együttműködő partnerintézeteket.

ÖSSZEGZÉS ÉS ZÁRÓ GONDOLATOK

A tudományos eredményeken alapuló betegközpontú ellátás egyik sarokköve, hogy a diagnózis meghatározásában a jelenleg legkorszerűbb technológiákat is felhasználjuk, így pl. mesterséges intelligencián alapuló szoftvereket is igénybe veszünk.

A bemutatott példa alapján érthető, hogy a használt MI-szűrő lehetővé teszi a betegnek beadott aktivitás jelentős csökkentését, mely számottevően csökkenti a vizsgálat kockázatát is azáltal, hogy jelentősen csökkenti a beteget és asszisztentst/orvost érő sugárzási dózist.

A tanuláson alapuló algoritmusok sajátossága, hogy viselkedésüket alapvetően meghatározza, hogy milyen képadatbázist „láttak” a tanítási folyamat során. Ezért kellő óvatossággal kell ezeket az algoritmusokat használni, és a használatot olyan meghatározott célterületekre, valamint indikációkra kell korlátozni, melyekre a tervezett komplex klinikai validáció megtörtént. Ellenkező esetben nem biztosított, hogy az a kép, amit az orvosnak

az MI-algoritmus szintetizál vagy a zajba „álmodik”, a valóságot mutatja. Az MI-t alkalmazó algoritmusok klinikai validációja és megbízhatóságuk tanúsítása eltér az orvosi gyakorlatban korábban használt szoftverektől, és számottevően költségesebb.

A validált MI-algoritmusok egy fontos segítséget, másodlagos megbízható véleményt képesek adni a leletező orvosnak, mely segítségével az orvos, továbbra is használva a rendelkezésére álló többletinformációt, valamint használva szakmai tapasztalatát és intuitív megérzéseit (15), várhatóan képes lesz olyan diagnózist adni, melynél a tévedési ráta számottevően alacsonyabb lehet, mint korábban. Mindez pedig várhatóan pozitív módon és jelentősen befolyásolja majd a beteg életkilátásait.

Az egészségügy válsága nem hazai, hanem globális jelenség; a feloldáshoz fontos, hogy a tudományos rendszer szemléletű gondolkodás (16) ne csupán az eszközök szintjén, hanem tágabb szinten is megjelenjen. Az MI-alapú eljárások, mint ahogy azt fent megmutattuk, képesek pl. számottevően lerövidíteni az effektív vizsgálati időt is. Ez pedig lehetővé teszi, hogy az így felszabadult időt az orvos pl. a beteggel való kommunikációnak szentelhesse. A betegközpontú ellátás másik sarokköve ugyanis éppen ez. Hiszen megfelelő empátikus odafigyeléssel és kommunikációval a betegnek jelentős mértékben segítünk feldolgozni a pszichés traumát, mely számottevően javítja a páciens bizalmát, valamint csökkenti a distresszt (17), mely az orvosi kezelése mellett alapvető fontosságú a gyógyulás folyamatában.

Az egészségügy rendszerszemlélete (16) „lehetővé teszi az egészségügyi szakemberek számára, hogy jobban megértsék a gyógyulás jelenségét”; az új technológiák bevezetése jelentős segítséget adhat ehhez, de önmagában a problémákat nem oldja meg. Ehhez a technológiák „okos felhasználása” és a tágabb összefüggések vizsgálata elengedhetetlen.

IRODALOM

1. Borbély K. Újdonságok és új lehetőségek az onkológiai betegek terápiás vezetésében: PET/MR klinikai alkalmazások. *Magy Onkol* 59:10-16, 2015
2. Quantitative Imaging with Tera-Tomo Suit. http://www.openhdx.de/media/Broschre%20Mediso%20TeraTomo%20Englisch%2001_01_2014.pdf
3. InterVeiv Fusion, multimodalitású képek feldolgozását lehetővé tévő munkaátlomás: http://www.mediso.hu/uploaded/INTF_1014_web.pdf
4. Doi K. Computer-aided diagnosis in medical imaging: Historical review, current status and future potential. *Comput Med Imaging Graph* 31:198-211, 2007
5. Razzak MI, Naz S, Zaib A. Deep learning for medical image processing: overview, challenges and the future. In: *Classification in BioApps. Lecture Notes in Computational Vision and Biomechanics*, vol. 26. Eds. Dey N, Ashour A, Borra S. Springer, 2018
6. Han C, Rundo L, Murao K, et al. Bridging the gap between AI and healthcare sides: towards developing clinically relevant AI-powered diagnosis systems. *Int J Comput Assist Radiol Surg*, 2020 <https://arxiv.org/abs/2001.03923v1>
7. FDA: Artificial Intelligence and Machine Learning in Software as a Medical Device. <https://www.fda.gov/medical-devices/software-medical-device-samd/artificial-intelligence-and-machine-learning-software-medical-device>
8. Van den Wyngaert T, Strobel K, Kampen WU, et al. The EANM practice guidelines for bone scintigraphy. *Eur J Nucl Med Mol Imaging* 43:1723-1738, 2016
9. Russo F. Validation of denoising algorithms for medical imaging. In: *Advances in Biomedical Sensing, Measurements, Instrumentation and Sys-*

- tems. *Lecture Notes in Computational Vision and Biomechanics*, vol. 26. Eds. Mukhopadhyay SC, Lay-Ekuakille A. Springer, 2010, pp. 93-105
10. *Neural Networks and Deep Learning*. <http://neuralnetworksanddeeplearning.com/index.html>
11. Convolutional autoencoders for image noise reduction. <https://towardsdatascience.com/convolutional-autoencoders-for-image-noise-reduction-32fce9fc1763>
12. Park SH, Han K. Methodologic guide for evaluating clinical performance and effect of artificial intelligence technology for medical diagnosis and prediction. *Radiology* 286:800-809, 2018
13. Swets JA. ROC analysis applied to the evaluation of medical imaging techniques. *Invest Radiol* 14:109-121, 1979
14. Tilbury JB, Van Eetvelt PW, Garibaldi JM, et al. Receiver operating characteristic analysis for intelligent medical systems—a new approach for finding confidence intervals. *IEEE Trans Biomed Eng* 47:952-963, 2000
15. Van den Brink N, Holbrechts B, Brand PLP, et al. Role of intuitive knowledge in the diagnostic reasoning of hospital specialists: a focus group study. *BMJ Open* 9:e022724, 2019
16. Capra F, Luisi PL. *Az élet rendszerszemlélete (egyetemi tankönyv) 15.1 fejezet: Az egészségügyi ellátás válsága*. Harmónia Háló, 2018 (eredeti mű: *The Systems View of Life – A Unifying Vision*, Cambridge Univ. Press, 2014)
17. Zwingmann J, Baile WF, Schmier JW, et al. Effects of patient-centered communication on anxiety, negative affect, and trust in the physician in delivering a cancer diagnosis: A randomized, experimental study. *Cancer* 123:3167-3175, 2017