

A mesterséges intelligencia nyújtotta megoldások helye és szerepe a jelen és a jövő orvoslásában

The impact of artificial intelligence systems in today's and tomorrow's medicine

Olar Alex¹, Pollner Péter^{1,2}, Csabai István¹

¹ Eötvös Loránd Tudományegyetem, Komplex Rendszerek Fizikája Tanszék

² Semmelweis Egyetem, Egészségügyi Menedzserképző Központ

Az elmúlt tíz évben a mesterséges intelligencia területe robbanásszerű növekedésnek indult, mostani fejlődésráta az ipari forradalomhoz hasonlítható, ahol az MI (mesterséges intelligencia) a korunk új árama. A jelen cikkben egy intuitív és közérthető bevezetőben taglaljuk a mesterséges intelligencia módszereit, valamint egy rövid ismertető után, két példa nyomán bemutatjuk a gépi látás orvosi alkalmazásait. Az első példa bemutatja, hogy rheumatoid arthritises betegek diagnosztikája hogyan tehető hatékonyabbá és gyorsítható fel drasztikusan, a második példa, pedig a mai országos szűrőprogramok (mammográfia, vastag- és végbéldaganatok) számítógépes döntéstámogatását alapozza meg. Alapvetésünk tehát, hogy az orvosi képelemzés és egyéb természettudományos adatok elemzése során kidolgozott módszerek gyakorlati hasznosítása és fejlesztése növelheti az életminőséget és az orvosi szolgáltatások színvonalát.

In the past 10 years, the field of artificial intelligence (AI) has expanded rapidly and the current rate of development can easily be compared to the second industrial revolution where AI is the new electricity of our era. In this article, we present a short and intuitive introduction to AI with two applications of computer vision in medical imaging. The first example presents a feasible way to improve and speed up the diagnosis of rheumatoid arthritis patients, while the second example elaborates on current nationwide screening programmes (mammography, colorectal cancer screening, etc.) via computer aided diagnostics solutions to mammography. Our main principal therefore is that biological images analysis and other scientific data analysis applications are a fruitful territory for scientific discovery and can significantly improve the quality of medical care and the standards of living.

BEVEZETŐ

A XX. század tudományos forradalma során megszületett az informatika, a mérnöki és matematika tudományok mellékágaként. Az első programok utasítások sorozatát tartalmazták, alapvető műveleteket csatoltak sorba és elsősorban szekvenciálisan hajtották végre. Kezdetben a legbonyolultabb algoritmusok is az emberi megoldásokat próbálták utánozni, apró lépésekre bontották az automatizált megoldás folyamatát és kitértek minden határesetre. Azonban már a korai informatika tudomány nagyjainak is elsődleges vágya volt megérteni,

hogy mi is az intelligencia: Claude Shannon már labirintusból kiszabaduló, mechanikus egeret, sakkozó robotokat épített és Alan Turing is már azon gondolkodott, hogyan lehetne mérni egy ágens intelligenciáját. Mivel az intelligencia egy alapvetően emberközpontú fogalom, nem definiálható teljesen objektív módon és definíció helyett pl. tesztek fogalmazhatóak meg, hogy egy cselekvés intelligens-e vagy sem. Az egyik legismertebbé vált teszt, a Turing-teszt is a gyakorlatban arról szól, hogy az MI el tudja-e hitetni a teszttel azt, hogy emberi módon intelligens-e. Az '40-es években már megjelent a mesterséges neuron elméleti modellje [1], amelyet az emberi agy neuronja inspirált. Ez a számítási egység gyakorlatilag a bemenetére adott jeleket súlyozottan összegzi, majd egy nem lineáris függvényen keresztül lead egy jelet a kimenetén. Nem sokkal később megalkották az első tanuló modellt a mesterséges neuronokat összekötve [2]. A perceptron modellt a bemeneti adatpontok alapján, kétesztályú/bináris klasszifikációra használták. Az első próbálkozások azonban nem arattak sikert, elsősorban a megfelelő számítási kapacitás és tanuló algoritmus hiánya miatt. Ha analógiát próbálunk keresni, akkor gyakorlatilag arról van szó, hogy megvolt a kalapács, de még nem lehetett tudni, hogy azt pontosan hogyan kell használni, és mi mindenre lehet jó. A sok paraméterrel rendelkező tanítható rendszerek, neurális modellek optimalizálására használt első algoritmust a '70-es, '80-as évek környékén dolgozták ki [3,4], de még ekkor sem állt rendelkezésre kellő mértékű számítási kapacitás. A technológia fejlődésének köszönhetően eljutottunk a 2000-es évek elején arra a szintre, amellyel a korábban még csak elméletben és nagyon kis skálán működő módszereket valódi problémák megoldására lehetett használni. Ennek hatására szervezték meg az első, természetes képfelismerő versenyeket [5], amit 2012-ben már egy konvolúciós, neurális architektúra nyert [5], valamint két évvel később egy hasonló modell [6] már az emberi pontosságot is meghaladta a képek kategorizálásában. Az elmúlt tíz évben pedig a mesterséges intelligencia területe robbanásszerű növekedésnek indult, a mostani fejlődésráta az ipari forradalomhoz hasonlítható, ahol az MI korunk új árama. A gépi látás, nyelvi elemzés és a megerősítéses tanulás területén is hihetetlen előrelépések születtek.

MESTERSÉGES INTELLIGENCIA AZ ORVOSLÁSBAN – BEVEZETŐ

Fókuszálunk elsősorban képek feldolgozására először. Az elmúlt évek tapasztalatai azt mutatják, hogy a gépi látás

területén az MI annyit fejlődött, hogy elérhetővé vált egy új, általánosan használható módszer tetszőleges mintázattfelismerésre, szakértői minták alapján, tanult módon. Az orvosi biológiában rengeteg olyan terület van, ahol szakorvosok sok-sok tapasztalat és tanulás után lesznek egyre jobbak, pl. radiológiai vagy mikroszkópos képek osztályozásában, kóros területek felismerésében. Hasonlóan, a gépi intelligencia modelljeit is először természetes képeken, emberek, állatok, tárgyak felismerésével tanítva az orvosi adathalmazokra alkalmazva egyre jobban teljesítő algoritmusok születtek. Azonban a mai mély tanulási módszerekhez, ahol mély tanulásnak (deep learning) nevezzük azokat a neurális hálókat, amelyek nagyon sok, egymás utáni réteggel rendelkeznek, akár több százal is, annak érdekében, hogy a mélyebb rétegek több hierarchián keresztül, komplexebb és átfogóbb reprezentációkat tanulhassanak meg. Az ezekhez szükséges adathalmazok mérete messze meghaladja az emberi tanulásához elegendő információ mennyiségét [7,8]. Különösen beszédes ez az orvoslásban, ahol általánosan elmondható, hogy még néhány kategória megtanulásához is akár milliós nagyságrendben kell példákat mutatni a gépnek nem kategorikus problémák esetén, ahol a cél valamilyen absztrakt reprezentáció tanulása [9,10] egy hatalmas adattenger minden egyes eleméről (nem felügyelt tanulás), ami általában egy több dimenziós vektor, az adathalmazok mérete százmilliós, akár milliárdos elemszámot is elérheti. Látható milyen nagy adathalmazról van szó, és hogy értsük és összehasonlíthassuk a nagyságrendet, egy szakorvos élete során is csak pár tízezres mintát lát. Komoly kihívást jelent tehát megfelelően általánosító modellek alkotása és tanítása orvosi mintákon úgy, hogy az a gyakorlat számára már értékelhető eredményt adjon. Egészségügyi alkalmazások során még további nehézséget jelent az adatok érzékenysége, ami miatt nehéz intézmények, de különösképpen országok között adatot megosztani. Ezért sokszor az eredményeket befolyásolja egy speciális műszer, egy új előkészítő eljárás, vagy akár egy sajátos technikával dolgozó laborasszisztens is. Az ilyen típusú változatosságra fel lehet és kell is készíteni a gépi rendszereket.

A mesterséges intelligencia által megoldható feladatok köre

A gépi tanuláson belül elkülöníthetünk három alapvető paradigmát:

- a felügyelt (supervised)
- nem felügyelt (unsupervised) tanulási módok,
- valamint a megerősítéses (reinforcement) tanulás.

Jelen cikkben az első kettőre térünk ki részletesebben.

Kiindulásként tekintsünk egy iskolapéldát. Két dimenzióban próbálunk egyenest illeszteni egy pontfelhőre. A hagyományos módszer szerint a legkisebb négyzetek módszerével keressük azt az egyenest, ami egy olyan $f(x) = mx + b$ lineáris függvény becslése, amely a pontokra a legjobban illeszkedik. Itt a függvény paramétereit előre meghatározott képletek alapján számoljuk ki. Ezzel szemben a gépi tanulási megol-

dás az alapoktól indul, és a pontok eltérését próbálja minimalizálni az egyenestől és így próbálgatva állítja be az egyenes paramétereit.

A képfelismerésnél alkalmazott gépi tanulási módszerek közül a mély tanulási rendszerek azok, amelyek egy ehhez hasonló típusú, csak éppen sok dimenzióban egy nemlineáris függvény illesztési feladatot végeznek el. A tanulófolyamat során, sztochasztikus módon mintákat kap a háló, amire a tanuló algoritmus optimalizálja a neurális architektúra kimenetét, annak érdekében, hogy a tanult mintákra adott válasz minimális hibaráttát adjon a tanulási mintákhoz képest. A mély neurális háló egyik meglepő tulajdonsága, hogy nem kizárólag egy adatbázisként funkcionálnak, vagyis nemcsak a tanító adathalmazom megismert eseteket képes reprodukálni, hanem új, korábban nem látott, de hasonló adatokon is jól teljesít, azaz képes a feladat megoldását általánosítani.

Megjegyezzük, hogy a mély tanulási technikák mellett, ahol sok neuron paraméterét kell beállítani, vannak technikák, amelyeknek az elsődleges célja az, hogy a tanuló periódus alatt megfelelő alacsony dimenziós reprezentációját, azaz kevés paraméterrel leírható jellemzését tanulják meg az adatoknak. Ezek az alacsony dimenziós reprezentációk két-, három dimenzióban akár vizualizálhatók is [11,12], amelyek alapján klaszterek alakíthatók ki. Nagy előnyük, hogy inherensen, az adatok alapján alakítják ki az emberi szem számára is befogadható struktúrákat. Leggyakrabban azonban a hétköznapi feladatok elvégzéséhez szükséges paraméterek száma nagy, azaz a reprezentációk magasabb dimenziójúak. Ezért ezeket a technikákat nem szoktuk közvetlenül alkalmazni, inkább csak más technikák eredményeinek javítására.

Az alapvetőbb paradigmák áttekintése után áttérünk néhány konkrét példa bemutatására.

Reumatológiai osztályozás röntgenfelvételek alapján

A rheumatoid arthritis (RA) egy viszonylag gyakori, gyulladásos autoimmun betegség, amely az ízületek kopását és deformálódását okozza, és komoly fájdalommal, mozgásszervi gyengeséggel jár. A betegség maga az orvostudomány jelen állása szerint gyógyíthatatlan, viszont korai felismeréssel és betegkövetéssel az életminőség nagyban javítható. A Magyarországon jelenleg alkalmazott módszertan szerint a páciensről rendszeresen készítenek kéz- és lábfej röntgenfelvételeket, ezek alapján az erre specializálódott radiológus szakorvosok, reumatológusok konklúziót vonnak le a betegség előrehaladottságáról, a páciens állapotáról. Ehhez a felvételeken található vizuális jelek gyors, átfogó, a részleteket nem elemző értékelési módszerét használják, mivel a pácienssel tölthető idő kevés, nincs idő részletesebb osztályozásra.

Ennél egy lényegesen időigényesebb módszer a Sharp/van der Heijde (SvH) pontozó szempontrendszer [13], amely a páciens összes kéz- és lábfejen található ízületét osztályozza, több fokozatú skálán egy- vagy kétoldali erózió és ízületitér-szűkület alapján. Sajnos ezt a pontozórendszert a világon gyakorlatilag sehol sem használják, hiszen rendkívül

időigényes, de pácienskövetésre rendkívül alkalmas, hiszen a betegség előrehaladását már korai szakasztól kezdve pontosan követi. A probléma megoldására, vagy legalább a kezdeti lépések kidolgozására indították az RA2 DREAM Challenge, Automated Scoring of Radiographic Joint [14] versenyt. Itt egy általános mesterséges intelligencia alapú rendszer fejlesztése volt a cél, amely képes az SvH pontszámot egy adott képre, majd az adott összes ízületre pontosan megbecsülni a látottak alapján. A versenyen a kutatócsoport dobogós helyezést ért el az összes modalításban [15]. A nyertes módszer lényege egy kéz- és lábfejröntgeneken ízületet automatikusan felismerő objektum detekciós neurális háló volt. A felismert struktúrákra egy további regressziós konvolúciós neurális háló jósolta az eróziót és a szűkületet.

Az első lépéshez, a detekciós tanuláshoz, kézzel digitalizálva be kellett jelölni pár száz kéz- és lábfejröntgenen a különböző ízületeket. Ezen a tanító halmazon már be lehetett tanítani egy objektum detekciós architektúrát. Miután megfelelő pontossággal sikerült az ízületeket automatikusan felismerni (a specificitás és szenzitivitás egyaránt meghaladta a 99%-ot), a detekciók alapján a röntgenfelvételekből ki lettek vágva az ízületek. A második lépésben több konvolúciós hálót felhasználva a megfelelő SvH pontszám betanítása történt. Itt bemeneti kép és a hozzá tartozó, szakorvosok által megállapított pontszámot kellett a gépnek reprodukálnia.

Véleményünk szerint a jövőben rengeteg ehhez hasonló területen fognak alkalmazni ehhez hasonló módszerekkel tanított képfelismerési és értékelési algoritmusokat. A távoli cél az lenne, hogy az értékelést, azaz a pontozást a gép orvosi felügyelet nélkül végezze. A kezelést megtervező orvos számára így már egy előfeldolgozott adat áll rendelkezésre, és a radiológiai felvétel aprólékos átvizsgálására szánt időt az orvos a páciens egyéb problémáinak felderítésére, egy komplex kezelés megtervezésére fordíthatja.

Emlődiagnosztika, mammográfiai lézió felismerése

Az emlődiagnosztika radiológiai felvételek alapján az egyik olyan modalitás, amit a legelőbbben próbálnak automatizálni. A modern gépi tanulás szempontjából szintén objektumfelismerési feladatról van szó, amelyben a kutató-

csoport korábban már rendkívüli eredményeket ért el [16]. Ma már tudjuk, hogy megfelelő körülmények között a gép általi diagnosztika akár pontosabb is lehet, mint egyes szakorvosok véleménye [17]. Az újabb kutatások célja lehet többféle, de továbbra is elsősorban az a kérdés, hogy van-e elvárt az egy adott mammogrammon. Ha ezt képes megállapítani a gép, akkor a döntését (malignus/negatív) alá is kell támasztani. Ehhez detektálni kell automatikusan az elváltozás típusát és helyét. Végül a képen felismert részletek alapján akár szöveges diagnózist is lehet készíttetni a géppel. Ez a terület azért kap kiemelt figyelmet, mivel a nőknél az emlő-daganat vezető halálok. Az országos szintű szűrőprogramok eredményes megvalósítása esetén olyan sok pácienssel kellene foglalkozni a radiológusoknak, ami pusztán emberi munkavégzéssel teljesíthetetlen.

Az automatizált rendszerek a széles körű, preventív orvoslási gyakorlatban, ahol igen nagy számban keletkeznek negatív leletek, gyakorlatilag rendszerkövetelményekké válnak.

ÖSSZEGRZÉS

Jelenlegi tudásunk szerint az MI felügyelt modelljei már alkalmasak a mintázatfelismerésen alapuló vizuális feladatok szakértői szintű elemzésére. A bevezetőben tárgyalt irodalom áttekintést ad a mesterséges intelligencia mérföldköveiről és alapvetően megalapozza az ismereteinket. A fentebb választott példák erősen kapcsolódnak a kutatócsoport eredményeihez, ahol korábbi és jelenlegi PhD hallgatók, Csabai István és Pollner Péter témavezetése alatt részt vettek mell-, vastag- és végbélrák szűrési kutatásokban, valamint nemzetközi versenyekben, amelyekben kiválóan szerepeltek. A választott szakirodalom ezeket az eredményeket prezentálja, valamint a jelenlegi interdiszciplináris tudományterület állását hivatott bemutatni. Láthatjuk, hogy már ma is rengeteg vállalkozás dolgozik orvosi felhasználásra szánt diagnosztikai eszköz és szoftver fejlesztésén, mély tanulás alapú technológiával. A jövőben ennek adaptálása elkerülhetetlen, részben a nagyszabású szűrőprogramok miatt, valamint a repetitív, időigényes és drága feladatok automatizálhatósága révén.

IRODALOMJEGYZÉK

- [1] McCulloch WS és Pitts W: A logical calculus of the ideas immanent in nervous activity, *The Bulletin of Mathematical Biophysics*, 1943; 5(4):115-133, <https://doi.org/10.1007/BF02478259>
- [2] Rosenblatt F: The perceptron: A probabilistic model for information storage and organization in the brain, *Psychological Review*, 1958; 65(6):386-408, <https://doi.org/10.1037/h0042519>
- [3] Linnainmaa S: Taylor expansion of the accumulated rounding error, *BIT*, 1976; 16(2):146-160, <https://doi.org/10.1007/BF01931367>
- [4] Rumelhart DE, Hinton GE és Williams RJ: Learning representations by back-propagating errors, *Nature*, 1986; 323(6088):533-536, <https://doi.org/10.1038/323533a0>
- [5] Russakovsky O, Deng J, Su H et al.: ImageNet Large Scale Visual Recognition Challenge, *International Journal of Computer Vision*, 2015; 115(3):211-252, <https://doi.org/10.1007/s11263-015-0816-y>
- [6] Krizhevsky A, Sutskever I és Hinton GE: ImageNet classification with deep convolutional neural networks, *Communications of the ACM*, 2017; 60(6):84-90,

- <https://doi.org/10.1145/3065386>
- [7] Ridnik T, Ben-Baruch E, Noy A és Zelnik-Manor L: ImageNet-21K Pretraining for the Masses, arXiv pre-print server, 2021, DOI: None arxiv:2104.10972.
- [8] Sun C, Shrivastava A, Singh S és Gupta A: Revisiting Unreasonable Effectiveness of Data in Deep Learning Era: IEEE.
- [9] Chen T, Kornblith S, Norouzi M és Hinton G: A Simple Framework for Contrastive Learning of Visual Representations, In Proceedings of the 37th International Conference on Machine Learning, szerk: Hal D, III és Aarti S, 2020, PMLR: Proceedings of Machine Learning Research, pp.1597–1607; URL: <https://proceedings.mlr.press/v119/chen20j.html>.
- [10] He K, Fan H, Wu Y, Xie S és Girshick R: Momentum Contrast for Unsupervised Visual Representation Learning, in 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020. <https://doi.org/10.1109/CVPR42600.2020.00975>
- [11] Van der Maaten L és Hinton G: Visualizing data using t-SNE, Journal of machine learning research, 2008; 9(11).
- [12] McInnes L, Healy J és Melville J: UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction, arXiv pre-print server, 2020, DOI: None arxiv:1802.03426.
- [13] van der Heijde DM, van Leeuwen MA, van Riel PL és van de Putte LB: Radiographic progression on radiographs of hands and feet during the first 3 years of rheumatoid arthritis measured according to Sharp's method (van der Heijde modification), J Rheumatol, 1995; 22(9):1792-6.
- [14] Challenges D: RA2 DREAM Challenge, 2021; URL: www.synapse.org/#!Synapse:syn20545111/wiki/603038.
- [15] TTK E: Gépi tanulás segítheti az autoimmun betegségek diagnosztizálását, 2021; URL: ttk.elte.hu/content/gepi-tanulas-segitheti-az-autoimmun-betegsegek-diagnosztizalast.t.3707.
- [16] Ribli D, Horváth A, Unger Z, Pollner P és Csabai I: Detecting and classifying lesions in mammograms with Deep Learning, Scientific Reports, 2018; 8(1), <https://doi.org/10.1038/s41598-018-22437-z>
- [17] McKinney SM, Sieniek M, Godbole V, et al: International evaluation of an AI system for breast cancer screening, Nature, 2020; 577(7788):89-94, <https://doi.org/10.1038/s41586-019-1799-6>

A SZERZŐK BEMUTATÁSA



Olar Alex, az Eötvös Loránd Tudományegyetem Informatika Doktori Iskolájának PhD-hallgatója, okleveles fizikus, jelenleg kutatásait az ELTE Komplex Rendszerek Fizikája Tanszéken, Csabai István csoportjában végzi. Fő érdeklődési területei az orvosi képelemzés mély neuronhálókkal, gépi

tanulási alapoktatás. Jelenleg több témával is aktívan foglalkozik: mammográfiai képelemzés, vastag- és végbélrák szűrés számítógépes segítése, valamint asztrociták felismerése humán mintákban a Semmelweis Egyetem különböző csoportjaival. Ezek mellett aktívan részt vesz a fizikus mesterképzés keretében, gépi tanulás képzésben, valamint orvosi utánképzésben a Semmelweis Egyetem Menedzserképző Központjával.



Pollner Péter PhD 1995-ben végzett az Eötvös Loránd Tudományegyetemen fizikus szakon, majd ugyanezt 2001-ben szerzett PhD fokozatot. Posztdokorként az ELTE Komplex Rendszerek Fizikája Tanszéken dolgozott nemlineáris rendszerek és káosz-elmélet területén, majd az ELTE Biológiai Fizika Tan-

székén működő MTA-ELTE Statisztikus és Biológiai Fizika Kutatócsoportjának munkatársa, később főmunkatársa. Kutatási területe a hálózattudományi módszerek és alkalmazások fejlesztése. Legutóbbi évtizedben aktívan dolgozik a Semmelweis Egyetem Egészségügyi Menedzserképző Központjában adattudományi elemzések és gépi tanulási témákban.



Prof. Csabai István egyetemi tanár, az MTA doktora. Az ELTE-n szerzett fizikus-biofizikus diplomát, majd PhD-t. Több évig dolgozott a Johns Hopkins Egyetemen az Egyesült Államokban. Multidiszciplináris kutatásaiban leginkább a tudomány olyan területeivel fog-

lalkozik, ahol az új technológiák előretörésével sok adat gyűjthető, és azok statisztikai elemzésével komplex jelenségek érthetőek meg, legyen az egy sejt, az ember alkotta Internet, vagy maga az Univerzum. Az MTMT alapján több mint 230 tudományos közleményére, (kumulatív impakt faktor 770), mintegy 40 000 független idézetet kapott, H-indexe 77.