

A mesterséges intelligencia a családorvosi ellátásban – irodalmi áttekintés

MÓCZÁR CSABA

ARTIFICIAL INTELLIGENCE FOR GENERAL PRACTITIONERS – LITERATURE REVIEW

Az egészségügyi ellátás során óriási mennyiségű adat keletkezik, ugyanakkor az elmúlt években a nagy adatbázisok feldolgozása terén is óriási előrelépés történt a mesterséges intelligencia technológiai fejlődésével. A mesterséges intelligencia gyakorlati alkalmazásai egyre inkább megjelennek az egészségügy területén, ezen belül a családorvosi ellátásban is. Ez a tanulmány nemzetközi irodalmi áttekintéssel mutatja be a mesterséges intelligencia alkalmazását a családorvoslásban. Egyelőre komplex, összefüggő rendszerek nem léteznek, leginkább egyes betegségek (például idült veseelégtelenség, diabetes mellitus, dementia stb.) predikciója, az adminisztratív feladatok segítése, és a döntési mechanizmusok támogatása azok a területek, ahol a mesterséges intelligencia különböző módszerei vizsgáznak, kísérleti jelleggel. A technológiai fejlődés üteme óriási, de a lehetőségek adta lelkesedés mellett azért tisztában kell lenni a technológia lehetséges veszélyeivel is.

Huge amount of data is generated while providing health care. Yet, there was the same huge progress in processing large databases with technological development of artificial intelligence in the recent years. Practical applications of artificial intelligence are increasingly established in healthcare, including the family medicine too. This study provides an overview of the international literature on artificial intelligence applications in family medicine. Complex, connected systems do not exist for the time being. Mainly the prediction of specific diseases (e.g., chronic kidney failure, diabetes mellitus, dementia, etc.), facilitating the data management, and supporting decision-making mechanisms are tested actually by specific methods of artificial intelligence for experimental reasons. The rate of technological progress is enormous, but with enthusiasm about the future, we must also be aware of potential dangers of this technology.

**mesterséges intelligencia, gépi tanulás,
családorvoslás, döntéshozatal**

**artificial intelligence, machine learning,
family medicine, decision-making**

dr. MÓCZÁR Csaba (levelezési cím/correspondence): Semmelweis Egyetem, Általános Orvostudományi Kar, Családorvosi Tanszék/ Semmelweis University, Faculty of Medicine, Department of Family Medicine; H-1085 Budapest, Üllői út 26.

Érkezett: 2024. március 2.

Elfogadva: 2024. április 18.

<https://doi.org/10.33616/lam.34.0299>

Az egészségügyi ellátórendszerek szerte a világon jelentős társadalmi, gazdasági és politikai erőterben dolgoznak. Az egészségügyi szolgáltatásokat az erőforrások optimális felhasználásával, a betegek veszélyeztetése nélkül kell biztosítani. Ehhez társul a fejlett országokban a lakosság előregedése és a vele járó multimorbiditás. Mindezek a folyamatok egyre jobban igénylik az egészségügyi ellátás és az egészségügyi ellátás megszervezése során keletkezett információk minél alaposabb feldolgozását és hasz-

nosítását. Az egészségügyi informatika minden területén óriási fejlődésnek lehetünk tanúi. A folyamat nagy mennyiségű, komplex adatbázis (big data) kialakulásához vezetett, amely kezelése kézenfekvővé tette a mesterséges intelligencia (MI) megjelenését az egészségügyi adatok feldolgozása területén is.

Az MI nem új koncepció, több mint 50 éve merült fel és az 1980-as és 1990-es években a neurális hálózatok megjelenésével vált népszerűvé. A fejlődésnek azonban eleinte gátat szabtak

a korabeli számítógépes kapacitások, de ezek a korlátok mára elhárultak, hála az eredetileg grafikai célokat szolgáló, nagy hatékonyságú processzorok (GPU-k) megjelenésének (1).

Mit is jelent a mesterséges intelligencia?

Egy számítógépes rendszer azon képessége, hogy az emberihez hasonló kognitív funkciókat tud utánózni, amilyen például a tanulás vagy a problémamegoldás.

Az MI nem új koncepció, több mint 50 éve merült fel és az 1980-as és az 1990-es években a neuralis hálózatok megjelenésével vált népszerűvé.

Hogyan működik a mesterséges intelligencia? A matematika és a logika használatával a számítógépes rendszer szimulálni képes azt az érvelési eljárást, amelyet az emberek is használnak, amikor új információk alapján tanulnak és döntéseket hoznak. A mesterséges intelligenciát használó számítógépes rendszerek előrejelzéseket nyújtanak vagy a

meglévő adatok mintázatán alapuló műveleteket hajtanak végre, és tanulni képesek a hibáikból, és így növelik a pontosságukat. Egy fejlett MI az új információkat rendkívül gyorsan és pontosan dolgozza fel, ami lehetővé teszi, hogy bonyolult helyzetekben is használjuk, például az önzetű autókban, a képfelismerő programokban vagy a virtuális asszisztensekben.

Mi a gépi tanulás?

A gépi tanulás (machine learning, ML) folyamata során a számítógép matematikai adatmodellekkel való betanítása történik, közvetlen utasítás nélkül. A gépi tanulás a mesterséges intelligencia (MI) egy ága. A gépi tanulás algoritmusok használatával azonosítja a mintákat az adatokban, majd ezekkel a mintákkal létrehoz egy előrejelzésekre alkalmas adatmodellt. A gépi tanulás eredményei az adatok és a tapasztalat mennyiségének növekedésével egyre pontosabbak lesznek – ahogyan az emberek is gyakorlással egyre ügyesebbé válnak (2).

A családorvoslásban is korán megjelentek az MI alkalmazásai, talán az egyik első a 2018-ban az FDA által engedélyezett diabeteses retinopathia szűrésére használt alkalmazás (3).

A kezdeti lendület után a mindennapi háziiorvosi gyakorlatba beépült alkalmazások egyelőre csak kis számban, inkább kísérleti jelleggel indultak.

Cikkemben a nemzetközi irodalom áttekintésével szeretnék képet adni az MI-nek a családorvosi területen történő alkalmazásának jelenlegi helyzetéről.

Módszer

Munkám egy irodalmi kitekintés, amely során a megfogalmazott cél elérése érdekében a PubMed orvosi irodalmi adatbázis utolsó öt évre (2019) visszamenő adatait tekintettem át. Az alábbi keresőszavak kombinációját alkalmaztam: primary care, family medicine, general practice, artificial intelligence, machine learning.

Az azonosságokat és a nem témába vágó cikkeket kiszűrtem. Nem vettem be az elemzésbe az MI elméleti felhasználhatóságáról szóló szakértői fejtegetéseket tartalmazó cikkeket, azokat azonban igen, amikor ugyanerről a témáról háziorvosok véleményét kérték ki tudományos módszerekkel feldolgozott cikkekből.

Az MI és a háziiorvosi dokumentáció

Kanadai kutatók felmérést végeztek alapellátásban dolgozók között az MI alkalmazásai lehetőségeit kérdezve a háziiorvosi ellátásban. A válaszadók többek között az egyik prioritásként az adminisztratív feladatok megkönnyítését említették. Leginkább a betegkarton kitöltésében, a gyógyszerfelírásban és a beutalók elkészítésében gondolták hasznosnak. A válaszadók véleménye szerint a technológia alkalmazásával a dolgozók kiegészése megelőzhető és több idő juthat a személyes orvos-beteg találkozóra (4).

Sørensen és munkatársai irodalmi áttekintése abból a célból készült, hogy összefoglalják azokat a kutatásokat, amelyeket a háziiorvosi gyakorlatban az adminisztratív feladatok támogatására és automatizálására alkalmazott gépi tanulási módszerek terén végeztek. Az egészségügyi és a mérnöki tudományok területeit lefedő adatbázisokban (PubMed, Embase, CINAHL teljes szöveg, Cochrane Library, Scopus és IEEE Xplore) kerestek és kilenc kutatási alapú attribútum mentén nyerték ki az adatokat az általános gyakorlathoz, az adminisztratív feladatokra, és a gépi tanulásra fókuszálva. A szerzők megállapítják, hogy a jelenlegi kutatásokban a diagnosztikus döntési algoritmusok lényegesen hangsúlyosabban jelennek meg, mint a valódi adminisztratív feladatokat érintő kutatások. Az adminisztratív feladatok közül a legtöbb cikk a betegelőjegyzéssel foglalkozik, illetve ennek bizo-

nyos aspektusaival (az előjegyzések lemondásának kezelése, az optimális előjegyzési taktika stb.). Mindezek az ellátás hatékonyabbá tételét célozzák. További területek a telemedicina, az orvos-beteg kommunikáció, intelligens adatbevitel (5).

A krónikus betegségek rizikó meghatározása, klinikai döntéstámogatás

Az irodalmat olvasva kétségtelenül a legtöbb tanulmány a különböző krónikus betegségek mielőbbi felismerésének lehetőségeit, a rizikó meghatározást, a különböző kockázati tényezők mesterséges intelligencia által használt algoritmusok által történő meghatározásáról jelenik meg. Az algoritmusok jelentősége a klinikai döntéshozatal támogatásában érvényesül, identifikálni a veszélyeztetett pácienseket a leghatékonyabb módon az elektronikus egészségügyi adatbázisok alapján és ezt követően az adott betegség diagnosztikája és kezelése.

Ezen a területen szerencsések azok a kutatóműhelyek, amelyek jelentős nagyságú egészségügyi adathoz, adatbázishoz (big data) tudnak hozzáférni.

Néhány példa: Kanadai kutatók a krónikus veseelégtelenség (chronic kidney disease, CKD) szűrésére egy MI-alapú algoritmuson alapuló döntéshozó platformot teszteltek 201 háziorvosi szolgáltató adatait elemezve. A cél a CKD-rizikó meghatározása és ez alapján a klinikai döntés támogatása. A módszer egy szövegbányászaton (natural language process, NLP) alapuló algoritmus alkalmazása volt, amely az egészségügyi adatokból az eGFR-t, az albuminuria mértékét, a demográfiai adatokat és a komorbid állapotokat vizsgálta. A vizsgálatból kizárták a nefrológiai gondozás alatt álló, dializált betegeket, a 85 évnél idősebbeket és az SGLT2-gátló (nátrium-glükóz kotranszporter-2-gátló) gyógyszert szedőket. 361 299 beteget szűrtek a módszerrel és 8194 3. stádiumú CKD-t találtak, akik közül 620 beteg magas, 2592 közepes rizikójú volt a CKD progressziója szempontjából. A szerzők véleménye az, hogy egy mesterséges intelligencia alapú klinikai döntéstámogató alkalmazás képes felismerni a CKD-ban szenvedő betegeket és képes a betegség stádiumának meghatározására, amely információk lehetővé teszik a klinikai döntéstámogatást (6).

A gépi tanuláson alapuló, nem diagnosztizált diabetes-előrejelzési modellek prediktív teljesítményét hasonlították össze dél-koreai kutatók a hagyományos statisztikai alapú előrejelzési mo-

dellekével. A 2014–2020-as Koreai Országos Egészségügyi és Táplálkozási Vizsgálati Felmérés (KNHANES) (n = 32 827) adatait használták fel. A ROC (receiver operating characteristic) görbe alatti területét (area under the curve, AUC) használták a gépi tanulás alapú és a hagyományos statisztikai alapú előrejelzés teljesítményének összehasonlítására. A nemet, életkort, nyugalmi pulzusszámot és derékbőrséget használva a gépi tanuláson alapuló modell magasabb AUC-t mutatott, mint a hagyományos statisztikai alapú előrejelzési modell (0,788 vs. 0,740). A vizsgált tulajdonságok számát bővítve – a nemet, az életkort, a derékbőrséget, a cukorbetegség családi anamnézisé, a magas vérnyomást, az alkoholfogyasztást és a dohányzási állapotot jellemzőként használva – a gépi tanuláson alapuló előrejelzési modell érzékenysége

tovább nőtt a hagyományos statisztikai alapú előrejelzési modellhez képest (AUC: 0,802 vs. 0,759). A gépi tanuláson alapuló előrejelzési modell a funkciók maximális kihasználásával az előrejelzési teljesítmény magasabb AUC-t mutatott, mint a hagyományos statisztikai alapú előrejelzési modell (0,819 vs. 0,765). A szerzők véleménye ez alapján, hogy a gépi tanuláson alapuló előrejelzési modellek antropometriai és életmód-tulajdonságok alkalmazásának segítségével felülmúlhatják a hagyományos statisztikai alapú előrejelzési modelleket a nem diagnosztizált cukorbetegség előrejelzésében (7).

378 256, az Egyesült Királyság háziorvosi praxisaiból származó, kezdetben szív- és érrendszeri betegségektől mentes beteg rutin klinikai adatait felhasználva egy prospektív kohorszvizsgálat történt a cardiovascularis rizikó státusz meghatározására. Négy gépi tanulási algoritmust (random forest, logisztikus regresszió, gradient boosting machines és neurális hálózat) hasonlították össze egy bevett algoritmussal (American College of Cardiology, ACC/AHA irányelvek) a 10 éven belül bekövetkező első cardiovascularis esemény előrejelzésére. A prediktív pontosságot a ROC-görbe alatti terület számításával értékelték (AUC), valamint meghatározták az érzékenységet, a specificitást, a pozitív prediktív értéket (PPV) és a negatív prediktív értéket (NPV) a 7,5%-os cardiovascularis kockázat előrejelzésére (a statinok megkezdésének küszöbértéke).

24 970 cardiovascularis esemény (6,6%) fordult elő. Az ACC-algoritmus alapján megállapí-

A családorvoslásban is korán megjelentek az MI alkalmazásai, az egyik első a 2018-ban az FDA által engedélyezett diabeteses retinopathia szűrésére használt alkalmazás volt.

A technológia fejlődése mellett, különösen a nagy adatbázisok feldolgozása terén elért fejlődés alapján a virtuális alapellátó orvos/családorvos valósággá válhat a nem túl távoli jövőben.

tott kockázathoz képest (AUC 0,728, 95% CI 0,723 $\pm$ 0,735) a gépi tanulási algoritmusok közül a random forest +1,7%-kal (AUC 0,745, 95% CI 0,739 $\pm$ 0,750), a logisztikai regresszió +3,2%-kal (AUC 0,760, 95% CI 0,755 $\pm$ 0,766), a gradient boosting machines technika +3,3%-kal (AUC 0,761, 95% CI 0,755 $\pm$ 0,766), a neuralis hálózatok +3,6%-kal (AUC 0,764, 95% CI 0,759 $\pm$ 0,769) javították a predikciót. A neuralis hálózati algoritmus 4998/7404 esetet jósolt (érzékenység 67,5%, PPV 18,4%) és 53 458/75 585 negatív esetet (specifititás 70,7%, NPV 95,7%), 355-tel (+7,6%) több betegnél jelzett cardiovascularis eseményt, mint a hagyományos algoritmus.

A szerzők a cikk összefoglalójában egyértelműen eredményesebbnek tekintik a gépi tanulási módszerek alapján történő rizikóbecslést és érdemeiként emelik ki, hogy több veszélyeztetett beteg lehet így megtalálni. Azonban ehhez hozzá kell tenni, hogy a gépi tanulási módszerek esetén a nyolc alaprizikófaktor mellett további 22 faktort is elemeztek, amelyek a cardiovascularis rizikóval összefügghetnek (például krónikus veseelégtelenség, pitvarfibrilláció stb.) (8).

A dementia és az enyhe kognitív károsodás aluldiagnosztizált az alapellátási gyakorlatban és kutatásban. Az elektronikus orvosi nyilvántartások (electronical medical records: EMR) szabad szövegű mezői olyan gazdag információforrást jelentenek, amely elősegíthetik a betegség felismerését, és lehetővé teszi a dementia kockázatának kitett populációk jobb megértését. Egy tanulmányban kanadai kutatók természetes nyelvi feldolgozást (NLP) alkalmaztak az EMR-ek dementiaival kapcsolatos jellemzőinek azonosítására és összehasonlították a felügyelt gépi tanulási modellek teljesítményét a dementiaiban szenvedő betegek osztályozása területén. A 2016 decemberéig gyűjtött EMR-jegyzetből összeállítottak egy 66 évnél idősebb alapellátási betegcsoportot a kanadai Ontarióban: 526, dementiaival rendelkező, és 44 148, dementiaival nem rendelkező beteget. Gépi tanulási modellek segítségével megvizsgálták az egyes, a dementiaira jellemző tulajdonság erősségét. Több mint 900, a dementiaival kapcsolatos jellemzőt azonosítottak és ezeket nyolc témába csoportosították (beleértve a tüneteket, a szociális, funkciót, megismerést). Ugyanakkor a gépi tanulás módszereinek hatékonyságát is vizsgálták a dementia ki-

mutatása tekintetében. E téren a LASSO (egyfajta regressziós elemzési módszer) teljesítménye volt a legjobb (érzékenység: 71,5%, specificitás: 99,8%) (9).

Egy dél-koreai tanulmánynak az volt a célja, hogy kiválassza a korábbi tanulmányokban azonosított, alacsony jövedelmű idős emberek depressziójához kapcsolódó tényezőket, és előrejelzési modellt dolgozzon ki. Ebben a tanulmányban 2975, alacsony jövedelmű családból származó idős embert vontak be a Korea Welfare Panel Study adatai alapján. Döntési fákat, logisztikai regressziót, neuralis hálózatokat és véletlen erdőket alkalmaztak a prediktív modell kidolgozásához. A modellek értékelését a pontosság igazolta. Azt találták, hogy a döntési fa esetében a legmagasabb a prediktív erő, 97,3%-os pontossággal. Mivel az idős emberek depressziójának előrejelzése számos befolyásoló tényezőtől függ, a döntési fa használata előnyös lehet egy szilárd előrejelzési modell felállításához, amely meghatározza az idős populáció depresszióját okozó létfontosságú tényezőket (10).

A terhességi diabetes mellitus (GDM) a nemkívánatos perinatalis események egyik kritikus oka. A korai terhesség korai GDM-értékének megbízható becslése megkönnyítené a veszélyeztetett anyák kiszűrését és szorosabb nyomon követését. Egy kínai tanulmány célja az volt, hogy egy modellt dolgozzanak ki a GDM korai előrejelzésére már az első trimeszterben. Az első trimeszterben lévő terhes nők jellemzőit Kelet-Kínából gyűjtötték 2017 és 2019 között. A random forest modellt és a logisztikus regressziós modellt alkalmazták a modellezésre. A modell teljesítményét itt is a ROC-görbe alatti területtel (AUC) jellemezték és nézték a diagnosztikus pontosságot, az érzékenységet és a specificitást. Összesen 1139 terhes nő (186 GDM-es) szerepelt a végső adatelemzésben. Jelentős különbségeket találtak az életkorban ($Z = -2,693$, $p = 0,007$), a terhesség előtti BMI-ben ($Z = -5,502$, $p < 0,001$), a háskörfogatban az első trimeszterben ($Z = -6,069$, $p < 0,001$), a PCOS (polycystás ovarium szindróma) meglétében ($\chi^2 = 101,024$, $p < 0,001$), rendszertelen menstruáció fennállásában ($\chi^2 = 6,578$, $p = 0,010$) és a cukorbetegség meglétében a családi anamnézisben ($\chi^2 = 15,266$, $p < 0,001$) a GDM-ben szenvedő résztvevők és GDM-ben nem szenvedők között. A random forest modell magasabb AUC-értéket ért el, mint a logisztikai regressziós modell (0,777 $\pm$ 0,034 vs. 0,755 $\pm$ 0,032), és jobb volt a GDM-megkülönböztető képessége a nem GDM-ektől (érzékenység: 0,651 $\pm$ 0,087 vs. 0,683 $\pm$ 0,084, specificitás: 0,813 $\pm$ 0,075 vs. 0,736 $\pm$ 0,08). A cikk eredményei alapján egy egyszerű modell

dolgozható ki a GDM kockázatának előrejelzésére gépi tanulási algoritmus segítségével, amely a terhesség előtti BMI, a haskőrfogat az első trimeszterben, az életkor, a PCOS, a rendszertelen menstruáció és a cukorbetegség családi anamnéziséen alapul. A modell könnyen kezelhető, és minden hozzá szükséges adat könnyen megszerezhető családorvosi ellátásban (11).

Virtuális családorvos

A virtuális családorvoslás egyik definíciója szerint egy mesterséges intelligencián alapuló rendszer, amelyet audio-/videokonferencia, chat vagy e-mail útján használnak és a beérkező adatokat valamilyen tanulási algoritmus alapján kondicionált MI-algoritmus értékeli és egy döntési algoritmus alapján ad javaslatot, leletet. A technológia jelen fejlődése mellett, különösen a nagy adatbázisok feldolgozása terén elért fejlődés alapján reális, hogy a virtuális alapellátó orvos/családorvos valósággá válhat a nem túl távoli jövőben. Az egészségügyi technológia egyik jelentős fejlesztése a távfelügyelet, amely a digitális technológiák használatával a betegek bizonyos egészségügyi adatait rögzítik és ezeket elektronikusan továbbítják az egészségügyi rendszerekbe. Ez a technológia olyan állapotok esetén használható, mint a cukorbetegség és a magas vérnyomás, ahol az olyan adatok, mint a vércukorszint és a vérnyomás automatikusan monitorozhatók az MI-rendszerekkel (12, 13).

A virtuális családorvoslás technikai feltételei egyre jobban fejlődnek, ezek közé tartoznak a számítógépekkel való kommunikációt támogató MI-n alapuló beszédfelismerő szoftverek. Már a mai rendszerek is a mesterséges intelligencia-algoritmusok segítségével elképesztő pontossággal és hatékonysággal konvertálják a kimondott szavakat nyomtatott szöveggé. Az MI vezérelte elektronikus egészségügyi adatbevitel, feldolgozás technikai alapjai már láthatók, sőt bizonyos részei már hozzáférhetők (14).

A cikk elején olvashattuk azokat a háziiorvosi praxisban is alkalmazható döntéshozási mechanizmusokat, amelyek a virtuális háziorvos munkáját segítheti. Ezeknek a technológiáknak az egységes rendszerbe integrálása még a jövő feladata, de a technológia ilyen fejlődése mellett elképzelhető, hogy megszületnek ezek a rendszerek. Annál is inkább, mert az egészségügy emberierőforrás-hiánya mindenütt a világon nagyon égető problémát jelentenek.

Összefoglalás

A cikkemben irodalmi kitekintést adtam a mesterséges intelligencia lehetséges alkalmazásairól a családorvosi gyakorlatban. A kép nem lehet teljes, mert nagyon sok az átfedő kutatás, illetve sok kutatás az orvoslás más területeit célozza, de lehet, hogy a jövőben a családorvoslásban is megjelenik. A kutatások egyik része a döntéshozatal-támogatást célozza, emellett jelentősek a technológiai jellegű fejlesztések is. Ugyanakkor nagyon sok kérdés fogalmazódik meg az MI használatával kapcsolatban, sok még a megoldandó jogi, etikai kérdés is a technikai kérdéseken túl. Az érdeklődő olvasók számára ajánlom a *JAMA Artificial Intelligence Resource Center* felületét, valamint a *New England Journal of Medicine* lapcsalád idén megjelenő új tagját *NEJM AI* címen. *Atul Butte*, a kaliforniai egyetem egészségügyi technológiai fejlesztési kara professzorának figyelmeztetésével zárom soraimat: „Ezek a nyelvi modellek, a mesterséges intelligencia bármely formája, ha arra kéri, hogy extrapoláljon azon túl, amit tud, akkor kezd kitalálni dolgokat, ezeket hallucinációknak nevezhetjük. Hasznos lenne, ha ezek a nagy nyelvi modellek megmondanák nekünk, hogy mikor hallucinálnak. Nem gyakran teszik ezt, ezért óvatosnak kell lenni. Úgy gondolom, hogy a technológia 6–12 havonta javulni fog, de egyelőre vigyáznunk kell a hallucinációkra” (15).

Irodalom

1. Lyanage H, Liaw S-T, Jonnagaddala J, et al. Artificial intelligence in primary health care: perceptions, issues, and challenges. *Primary Health Care Informatics Working Group Contribution to the Yearbook of Medical Informatics* 2019;2019:41-6.
<https://doi.org/10.1055/s-0039-1677901>
2. <https://azure.microsoft.com/hu-hu/resources/cloud-computing-dictionary/what-is-artificial-intelligence#%C3%B6nvezet%C5%91-aut%C3%B3k> (Utolsó elérés: 2024. 02. 01.)
3. Abràmoff MD, Lavin PT, Birch M, et al. Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices. *NPJ Digit Med* 2018;1(1):39.
4. Tara L, Craig-Neil A, Macklin J, et al. Priorities for artificial intelligence applications in primary care: A Canadian deliberative dialogue with patients, providers, and health system leaders. *J Am Board Fam Med* 2023;36:210-20.
5. Sørensen, et al. Machine learning in general practice: sco-

- ping review of administrative task support and automation, *BMC Primary Care* 2023;24:14. <https://doi.org/10.1186/s12875-023-01969-y>
6. Mosa AI, Watts D, Navdeep T. Impacting management of chronic kidney disease through primary care practice audits: A quality improvement study. *Canadian Journal of Kidney Health and Disease* 2022;9:1-7.
 7. Choi S Gy, Oh M, Park D-H, et al. Comparisons of the prediction models for undiagnosed diabetes between machine learning versus traditional statistical methods, *Scientific Reports* 2023;13:13101. <https://doi.org/10.1038/s41598-023-40170-0>
 8. Weng SF, Reys J, Kai J, Garibaldi JM, Qureshi N. Can machine-learning improve cardiovascular risk prediction using routine clinical data? *PLoS ONE* 2017;12(4): e0174944. <https://doi.org/10.1371/journal.pone.0174944>
 9. MacLagan LC, Abdalla M, Harris DA. Can patients with dementia be identified in primary care electronic medical records using natural language processing? *J Healthc Inform Res* 2023;7(1):42-58. <https://doi.org/10.1007/s41666-023-00125-6>.
 10. Kim K-Y, Kim J-H, Rhee H-S, et al. Development of a prediction model for the depression level of the elderly in low income households: using decision trees, logistic regression, neural networks, and random forest. *Scientific Reports* 2023;13:11473. <https://doi.org/10.1038/s41598-023-38742-1>
 11. Wang, et al. An early model to predict the risk of gestational diabetes mellitus in the absence of blood examination indexes: application in primary health care centres. *BMC Pregnancy and Childbirth* 2021;21:814. <https://doi.org/10.1186/s12884-021-04295-2>
 12. Walker RC, Tong A, Howard K, Palmer SC. Patient expectations and experiences of remote monitoring for chronic diseases: systematic review and thematic synthesis of qualitative studies. *Int J Med Inform* 2019;124:78-85. <https://doi.org/10.1016/j.ijmedinf.2019.01.013>
 13. Fagherazzi G, Ravaud P. Digital diabetes: perspectives for diabetes prevention, management and research. *Diabetes Metab* 2019;45(4):322-9. <https://doi.org/10.1016/j.diabet.2018.08.012>
 14. <https://s10.ai/blog/digitalization-of-health-records-using-robot-medical-scribes> (Utolsó elérés 2024.01.31.)
 15. <https://www.medscape.com/viewarticle/996905> (Utolsó elérés 2024. 01. 31.)



Válogatás az eLitMed.hu orvostudományi portál Ökológia rovatának szemlézéseiből

Úton a karbonsemleges intenzív ellátás felé

A rangos *BMJ* szakfolyóiratban megjelent tanulmány, a *Towards net zero: critical care* az intenzív ellátás környezeti hatásainak mérséklését járja körül. A kórházakon belül az intenzív ellátásnak különösen nagy a karbonlábnyoma, és más jelentős negatív környezeti hatások is kapcsolódnak hozzá – kezdve az egyszer használatos tárgyaktól a különféle beavatkozások energiaigényéig. A fenntarthatóbbá alakítás hat kulcsszava a következő: elkerülés, csökkentés, újrahasználat, újrafeldolgozás, kutatás és újragondolás. Mindez persze anélkül, hogy fel lenne áldozva a biztonság és a minőségi ellátás.

Az elkerülés kapcsán már az intenzív ellátásra jutás elkerülése is felmerül, ami nyilvánvalóan túlmutat az egyes egészségügyi dolgozók felelősségén – itt többek között a közegészség kérdésköre említendő. Az intenzív osztályok dolgozóinak (nem egyszerű) szerepe az elkerülés kapcsán például abban áll, hogy csak azokat részesítsék ilyen ellátásban, akiken valóban ez segít. A csökkentés kulcsszó alá tartozik például az intenzív osztályokon töltött idő optimalizálása is, valamint a „kevesebb több” elvének az alkalmazása: azaz annak a felismerése, hogy bizonyos beavatkozások érdemben nem javítanak a beteg állapotán, azonban számos negatív hatással járnak (mind társadalmi, mind környezeti vonatkozásban). Az sem mindegy, hogy milyen a kórház energiaellátása (megújuló energiaforrások), de az újrahasználat formája lehet az is, amikor egy-egy tárgy egyetlen kórházi beteget kísér végig a kórházi tartózkodása alatt. A következő lehetőség az újrafeldolgozás, melynek kórházi lépése a szelektív gyűjtés. Kezdve attól, hogy eleve minél inkább újrahasznosítható tárgyak kerüljenek be az ellátásba, egészen odáig, hogy a lehető legkönnyebb legyen a kórházi szelektív gyűjtés az egyes dolgozók számára, számtalan lehetőség létezik.

A szemlézett tanulmány számtalan konkrét javaslatot is megfogalmaz, kutatási eredményekkel alátámasztva az egyes változtatások környezeti és humánegészségügyi jelentőségét.

<https://elitmed.hu/ilam/okologia/uton-a-karbonsemleges-intenziv-ellatas-fele>



A szemlézések az eLitMed.hu orvostudományi portálon a *Rovatok* menüpont alatt találhatók. A cikkek közvetlen elolvasásához okostelefonjának QR-kód-olvasó alkalmazását irányítsa a kiválasztott cikk melletti kódra.