Izvorni znanstveni rad

Original Scientific Article

Umjetna inteligencija i donošenje odluka u medicini: pogled ključnih dionika zdravstvenog sustava

Dr. sc. Anamaria Malešević

Laboratorij za etiku digitalnih tehnologija u zdravstvu (Digit-HeaL), Hrvatsko katoličko sveučilište

E-mail: anamaria.malesevic@unicath.hr

ORCID: 0000-0002-8162-3183

Izv. prof. dr. sc. Anto Čartolovni

Medicinski fakultet, Hrvatsko katoličko sveučilište

E-mail: anto.cartolovni@unicath.hr

ORCID: 0000-0001-9420-0887

Sažetak

Umjetna inteligencija transformira zdravstvenu skrb i uvodi promjene u svakodnevne aspekte rada liječnika. Potencijal primjene umjetne inteligencije u kliničkoj praksi značajan je, ali isto tako potrebno je osvijestiti pojavu rizika i izazova koji dolaze sa samom implementacijom. Laboratorij za etiku digitalnih tehnologija u zdravstvu (Digit-HeaL) proveo je kvalitativno istraživanje s ključnim dionicima zdravstvenoga sustava 2021. godine. Ključni dionici uključivali su liječnike, pacijente, rukovoditelje zdravstvenih institucija, IT inženjere, pravnike i donositelje javnih politika. U istraživanju su korišteni hipotetski scenariji budućnosti. Rad prikazuje rezultate povezane s mišljenjem liječnika oko korištenja umjetne inteligencije za donošenje odluka te stavove ostalih ključnih dionika oko povjerenja ako se dijagnostički zaključci umjetne inteligencije i liječnika razlikuju. Liječnici u istraživanju ističu da se donošenje odluka ne može prepustiti isključivo tehnologiji te da umjetna inteligencija zahtijevanja krajnju osobu, odnosno kontrolu i nadzor od strane liječnika. Liječnici na umjetnu inteligenciju gledaju kao dodatni alat, a svoju ulogu vide u integriranju podataka i donošenju odluka. Ostali ključni dionici zdravstvenog sustava iskazuju veće povjerenje prema liječnicima nego umjetnoj inteligenciji ako bi se njihove dijagnoze razlikovale, izuzev pravnika koji su u jednakoj mjeri iskazivali povjerenje prema umjetnoj inteligenciji. Zaključno, puni potencijal umjetne inteligencije u medicini može se ostvariti kroz međusobnu suradnju ključnih dionika koji će usmjeravati razvoj prema izradi dodatnog alata u procesu donošenja odluka, a ne samostalnoga sustava.

Ključne riječi: donošenje odluka, klinička praksa, liječnik, medicina, umjetna inteligencija, rizik

Artificial intelligence and decision-making in medicine: The view of key stakeholders of the healthcare system

Summary

Artificial intelligence (AI) is transforming healthcare and changing the everyday aspects of physicians' work. The potential for using AI in clinical practice is significant, but raising awareness of the risks and challenges associated with its implementation is also necessary. Digital Healthcare Ethics Laboratory (Digit-HeaL) conducted a qualitative study with key stakeholders of the healthcare system in 2021. Key stakeholders included physicians, patients, healthcare managers, IT engineers, lawyers, and public policy makers. The study employed hypothetical future scenarios. The paper presents results related to physicians' opinions on using artificial intelligence (AI) in decision-making and the perspectives of other key stakeholders regarding trust in cases where AI

diagnostic conclusions differ from those of physicians. Physicians in the study emphasized that decision-making cannot be entirely entrusted to technology and that AI requires human authority, i.e., control and oversight by physicians. Physicians view AI as an additional tool and see their role as integrating data and making decisions. Other key stakeholders in the healthcare system expressed greater trust in physicians than in AI when their diagnoses differed, except for lawyers, who showed equal trust in both physicians and AI. In conclusion, the full potential of AI in medicine can be realized through the collaborative efforts of key stakeholders, guiding development towards creating a supplementary tool for decision-making rather than an autonomous system.

Keywords: decision-making, clinical practice, physician, medicine, artificial intelligence, risk

1. Uvod

Primjena umjetne inteligencije u zdravstvu ima velik i značajan potencijal, od obrade zdravstvenih podataka, dijagnostike, personaliziranog liječenja do prevencije i upravljanja globalnim javnozdravstvenim rizicima. Zbog dobrobiti koju mogu unijeti u zdravstvenu skrb, danas različite tehnologije koje se temelje na umjetnoj inteligenciji privlače pozornost korisnika (liječnika i pacijenata), istraživačke zajednice i zdravstvenih sustava u cjelini. Entuzijazam oko primjene umjetne inteligencije uočljiv je u različitim granama medicine, od radiologije (1,2), neurologije (3), nefrologije (4), dermatologije (5) i onkologije (6), a njena primjena je već prilično proširena, od naručivanja na preglede, digitalizacije zdravstvenih kartona, prilagodbe primjene lijekova (7) do analize i detekcije određenih bolesti i stanja. Umjetna inteligencija može pomoći u identificiranju rizičnih pacijenata i optimizaciji samog ishoda liječenja (8).

Pitanje donošenja odluka zastupljeno je kroz različite aspekte kada govorimo o umjetnoj inteligenciji, budući se može primijeniti u različitim područjima, poput tumačenja grafikona i podataka, praćenja na daljinu, predikcije dijagnoze i prognoze bolesti (9). Primjena umjetne inteligencije kao dijagnostičkog alata može pomoći u donošenju odluka kroz identificiranje ključnih obrazaca u velikim skupovima podataka (10). Primjerice, algoritam umjetne inteligencije treniran na mamografskim podacima pokazao je bolju dijagnostičku učinkovitost, odnosno veću osjetljivost u otkrivanju karcinoma dojke u odnosu na oslanjanje na znanje i iskustvo radiologa bez njene primjene (11). S druge strane, implementacija umjetne inteligencije povlači za sobom mnoge društvene, etičke i pravne izazove koji traže društvene, institucionalne i regulatorne odgovore.

Stoga je cilj ovoga istraživanja bio identificirati očekivanja i strahove liječnika povezane s primjenom umjetne inteligencije u zdravstvenu skrb. Jedan od specifičnih ciljeva bio je utvrditi način donošenja odluka kada se dijagnostički zaključci umjetne inteligencije i liječnika razlikuju.

2. Metode istraživanja

Istraživanje je proveo Laboratorij za etiku digitalnih tehnologija u zdravstvu (Digit-HeaL) Hrvatskog katoličkog sveučilišta u Zagrebu krajem 2021. godine putem polustrukturiranog intervjua (uživo ili putem online platformi) sa 75 ključnih dionika u zdravstvu. Među ispitanicima je bilo 12 liječnika, 11 rukovoditelja zdravstvenih ustanova, 15 pacijenata, 15 IT inženjera i 12 pravnika koji rade u zdravstvu te 10 donositelja javnih politika. Uzorak u istraživanju bio je namjerni ili uzorak „snježne grude“, odnosno birani su stručnjaci u području koji su bili kontaktirani putem službenog e-maila ili kroz preporuke samih istraživanja. U sklopu intervjua korišteni su imaginirani scenariji budućnosti koji su bili autorsko djelo istraživačkog tima, a jedan od njih koji je nazvan *Liječnik 4.0 i budućnost medicine*[1] opisivao je

1 Scenarij i protokol istraživanja dostupni na zahtjev

bolnicu koja je odlučila uvesti asistenta (Cronka) koji počiva na umjetnoj inteligenciji u sve aspekte rada. Scenariji su imali za cilj povezati buduće situacije sa sadašnjosti, obzirom da se predviđena radnja zbivala u 2030. godini. Kroz scenarije koji su bazirani na anticipatornoj etici i time omogućavaju razmatranje etičkih i društvenih izazova koje su još u fazi razvoja (12, 13) stvarale su se hipotetske mogućnosti, bez utvrđivanja točnosti ili ispravnosti, već samo kroz ilustriranje odluka i posljedica (14, 15). Intervjui su snimani putem snimača te su kasnije transkribirani, nakon čega je uslijedila kvalitativna analiza kroz konsolidaciju, sažimanje i tumačenje izrečenoga u intervjuu (16). Prosječno trajanje intervjua iznosilo je 47 minuta, a tematske cjeline koje su bile obuhvaćene uključivale su općenito korištenje tehnologija i iskustvo zdravstvenog sustava, korištenje digitalnih tehnologija u zdravstvenoj skrbi, stavovi i mišljenja o implementaciji digitalnih tehnologija u medicinsku skrb te budućnost zdravstva. Prikazani su rezultati koji se odnose na istraživačka pitanja: 1. Kakvo je mišljenje liječnika o korištenju umjetne inteligencije za donošenja odluka? 2. Kome ostali ključni dionici zdravstvenog sustava, posebice pacijenti iskazuju povjerenje ako se razlikuju dijagnostički zaključci liječnika i umjetne inteligencije?

Za provedbu istraživanja dobivena je Odluka Etičkog povjerenstva Hrvatskog katoličkog sveučilišta kojom je potvrđeno da je istraživanje provedeno u skladu s pravilima i zakonskim regulativama provođenja istraživanja. U prikazu rezultata koristi će se kodna imena koja su dodijeljena sudionicima, a sastoje se od skupine ključnih dionika kojoj pripadaju (primjerice, liječnik) te rednog broja provedenog intervjua.

3. Rezultati

Sudionicima je bilo postavljeno pitanje koje se odnosilo na razlikovanje dijagnoze, to jest dijagnostičkog zaključka kojega je dobio liječnik uz pomoć ili bez sustava umjetne inteligencije koji je u prikazanom scenariju nazvan *Cronko*. Liječnici su trebali odgovoriti kako bi se postavili u slučaju da algoritam umjetne inteligencije (Cronko) sugerira neku drugu dijagnozu koja nije u skladu s njihovom kliničkom procjenom. Također, u samom pitanju[2] naglašeno je da točnost algoritma iznosi 92 %, ali zbog same prirode istoga, nejasan je način kako dolazi do dijagnoze.

Među liječnicima koji su sudjelovali u istraživanju prevladava stav da se donošenje dijagnostičkog zaključka ne smije prepustiti isključivo tehnologiji, već da iza dijagnoze treba uvijek stajati liječnik. Liječnik 3 navodi: *„Donošenje odluka na kraju krajeva ne može se prepustiti nikakvom algoritmu, dakle nekakvom sustavu koji ima svoje algoritme. Odluka je mislim nešto što je svojstveno biću koje ima nekakvu slobodu. I u toliko to nešto, to je baš liječnički posao. Zato što je on educiran u tom području.“* Liječnici smatraju da umjetna inteligencija zbog svoje brzine obrade podataka treba služiti liječniku kao dodatna dijagnostička metoda, alat ili kako navodi jedan od liječnika „produžena ruka“. Navodeći ljudske nedostatke koji su uobičajeni u svim poslovima, pa tako i u liječništvu, liječnici smatraju da u eri umjetne inteligencije imaju i dalje glavnu ulogu kroz integriranje podataka i donošenje odluke koja je najbolja za nastavak liječenja.

No, zabilježeni su i drugačiji pogledi oko donošenja odluka u eri umjetne inteligencije. Liječnik 7 navodi: *„U mom radiološkom slučaju ja bih uvijek prvo vjerovao stroju, onda napravio test opet skupa sa strojem i onda bi rekli čovjeku, evo ga na, stroj bolji od mene.“* Nekolicina ističe da nije moguće ići dalje ako postoje dvije paralelne dijagnoze koje se ne slažu te navode kako bi u tom slučaju detaljno istražili zašto je došlo do toga, preispitali vlastite dijagnoze, tražili podudaranje te objasnili pacijentu situaciju i potražili treće mišljenje.

2 Pitanje je glasilo: Cronko je točnu dijagnozu postavljao u 92% slučaja, međutim zbog prirode samog algoritma, nejasan je proces kojim umjetna inteligencija dolazi do dijagnoze. S druge strane, liječnici su sposobni pacijentu objasniti proces koji ih je doveo do dijagnostičkog zaključka, međutim ljudski postotak točnosti je nešto niži. Kada bi se Vaša dijagnoza razlikovala od Cronkove kako biste se postavili prilikom savjetovanja pacijenta o njegovom liječenju?

Liječnici su isticali kako smatraju da umjetna inteligencije neće biti nikada u mogućnosti sama donositi odluke te da će sustav „zahtijevati krajnju osobu“, odnosno kontrolu i nadzor liječnika. Liječnik 2 i liječnik 12 ističu da liječnik danas ne može bez tehnologije donositi kliničke odluke te da joj mora vjerovati kada se njome služi kako bi doveo do što boljeg ishoda, ali da se sama odluka nikada ne smije prepustiti isključivo umjetnoj inteligenciji. Jedan od razloga je taj što u medicini postoji odgovornost koju umjetna inteligencija ne može preuzeti, već čovjek mora biti odgovoran za eventualne posljedice u slučaju pogrešnog postupanja kod dijagnostičkog zaključivanja. Liječnik 12 naveo je: *„Znači, mi kad smo za nekaj odgovorni, smo za nekaj odgovorni. Algoritam nemre bit za niš odgovoran. Prema tome, njegov svaki nalaz i postupak mora netko amenovati.“* I drugi liječnici smatraju da ako algoritam i donese dijagnostički zaključak, liječnik bi ga trebao validirati te potvrditi ili odbaciti.

Liječnici ističu i problem grešaka koje se mogu dogoditi i kod umjetne inteligencije. Liječnik 11 ističe da bi trebalo puno podataka procesuirati kako bi se došlo do konačne dijagnoze i dodaje: *„nisam sigurna vjerujem li u stručnost takve procjene“*. Liječnik 3 komentira to, navodeći da *„postoje neke situacije u kojima bi umjetna inteligencija mogla zapravo precijeniti vrijednost nečega što se vidi ili podcijeniti važnost nečega“*. Liječnici stoga budućnost vide kao suradnju umjetne inteligencije i liječnika, gdje će se prednosti umjetne inteligencije koristiti kako bi im se olakšao posao u onim aspektima gdje je to moguće, ali se neće dopustiti potpuna zamjena u ključnim dijelovima skrbi, kao što je donošenje konačne odluke, odnosno dijagnostičkog zaključka. Liječnik 9 zaključuje da *„mora biti jasno, ne smije tu biti nekih dubioznih situacija gdje je pacijent prepušten, ono, nekakvoj odluci stroja. U tome će uvijek biti uključeni ljudski faktor. Tako da, nisam pesimist u smislu da će strojevi preuzeti dijagnostičko odlučivanje.“* Liječnik 12 navodi da će upravo sinergija između liječnika i umjetne inteligencije dovesti do najboljih ishoda za pacijenta *„neke stvari baš će trebati koji puta čovjek, jer ne znam, ima tu puno nekakvih kriterija po kojem se dolazi do nekakve dijagnoze i tak dalje. Ovoga, ja ne kažem da to ne može umjetna inteligencija, ona će biti sigurno u 90% točna, ali u kombinaciji s čovjekom to će biti na 100%.“*

U istraživanju je identificiran i strah od pretjeranog oslanjanja na tehnologiju posebice kod mlađih liječnika koji nisu imali prethodno iskustvo u donošenju odluka bez primjene nekih tehnoloških inovacija kao i neki drugi društveni i infrastrukturni izazovi. Identificirani izazovi uključuju nedostatak društvene spremnosti kao što je nezadovoljavajuća razina digitalne i medicinske pismenosti, neusklađenost obrazovanja, odnosno medicinskog kurikuluma s trenutnim potrebama u zdravstvenom sustavu i sve većem napretku tehnologije. Također, identificirana je zabrinutost oko financijskih resursa i pravnog okvira koji bi trebali omogućiti razvoj i implementaciju umjetne inteligencije u zdravstvu na održiv način. Postojeći infrastrukturni problemi mogli bi se negativno odraziti na sam proces implementacije, a sudionici posebno ističu trenutno nepovezanost sustava, manjak digitalnog pristupa podatcima i tehničke poteškoće samih sustava koji se trenutno u zdravstvu koriste.

Među sudionicima koji su bili pacijenti, većina ih je iskazala povjerenje u liječnikovu dijagnozu ako bi se dijagnoze razlikovala od one koju sugerira algoritam umjetne inteligencije. Kao glavne razloge za to naveli su tehničke ograničenosti same tehnologije i moguće greške. U slučaju neslaganja liječnikove dijagnoze s onom koju sugerira umjetna inteligencija, liječnikovu odluku smatraju superiornijom jer smatraju da je to njegova ekspertiza. Uz to navode i neke druge aspekte koji su im bitni, primjerice, smatraju da liječnik prilikom dijagnosticiranja u obzir uzima i druge parametre kojima umjetna inteligencija nema pristup. Također, neki su isticali mogućnost razgovora s liječnikom i zajedničko donošenje odluke, koje nije moguće u tome obliku s algoritmom jer ne može opisati proces donošenja dijagnostičkog zaključka. Dio pacijenata ipak bi bio skloniji vjerovati dijagnostičkom zaključku algoritma, smatrajući da je vjerojatnost pogreške znatno manja od liječničke pogreške.

Istraživanjem je uočeno da postoji i treća skupina kod pacijenata i inženjera koja ne bi vjerovala ni liječniku niti algoritmu, već bi se, ako dođe do razlike u dijagnozi, pouzdali u vlastito donošenje odluka oko zdravstvenog stanja. Dio ispitanika istaknuo je potrebu za traženjem trećeg mišljenja, ili nekog neovisnog stručnjaka ili drugog algoritma, koji bi u tome slučaju donio vlastitu dijagnozu. Najveće povjerenje u dijagnoze umjetne inteligencije uočeno je među pravnicima gdje od 12 sudionika, 5 je bilo naklonjeno mišljenju umjetne inteligencije, dok najmanje među donositeljima javnih politika gdje među 10 sudionika samo je jedan bio naklonjen preferiranju tog dijagnostičkog zaključka.

4. Rasprava

Umjetna inteligencija transformira zdravstvenu skrb i predstavlja značajan potencijal za unaprjeđenje kvalitete zdravstvene skrbi u budućnosti. Kako bi se u potpunosti iskoristio njen potencijal koji bi imao održivu primjenu, bitno je voditi računa o etičkim, društvenim i pravnim izazovima koji prate tu transformaciju. Izazovi uključuju pitanje privatnosti i informiranog pristanka, upravljanja osobnim podatcima, autonomiju pacijenta, transparentnosti, objašnjivosti, sigurnosti i još mnoge druge (10). Potrebno je osvijestiti važnost kritičkog promišljanja kod korištenja umjetne inteligencije i svjesnosti oko svih rizika i potencijala koji se mogu pojaviti te integrirati ekspertizu, znanje i iskustvo liječnika s tehničkim mogućnostima (17). Također, ključna je suradnja različitih ključnih dionika iz različitih sustava, zdravstvenog, pravnog, akademskog i tehničkoga kako bi se stvorile smjernice i okvir za korištenje umjetne inteligencije kod donošenja odluke u dijagnostičkom zaključivanju (10). Ispitanici našeg istraživanja istaknuli su da umjetna inteligencija treba ići u smjeru razvoja koji će omogućiti liječnicima dodatni alat ili dijagnostičku metodu, a ne usmjeravati je prema alatu koji će donositi samostalno dijagnoze. Korištenje umjetne inteligencije kao dodatnog dijagnostičkog alata može značajno poboljšati performanse samih liječnika i smanjiti pogreške u medicini (10, 11). Jednako tako može poslužiti pacijentima za dodatno informiranje i osnažiti ih za aktivno sudjelovanje pri zajedničkom donošenju odluka (19). Dileme koje mogu nastati ukoliko dođe do neslaganja u dijagnostičkoj procjeni između liječnika i umjetne inteligencije ukazuju na to da bi liječnici trebali stajati iza svoje ekspertize ili ju dodatno pokušati potvrditi neovisnim trećim mišljenjem ili ponovljenim testovima i pregledima. Istraživanje provedeno među studentima medicine, među kojima su bili i studenti iz Hrvatske, pokazalo je da bi budući liječnici u takvoj situaciji najčešće stali iza svog dijagnostičkog zaključka i pokušali ga dodatno potvrditi, a tek manji broj njih bi se bezprigovorno priklonio mišljenju algoritma (18). Provedeno istraživanje je prvo takvo u Hrvatskoj koje uključuje široki spektar ključnih dionika zdravstvenog sustava i njihovo mišljenje i stavove oko korištenja umjetne inteligencije, kao i očekivanja i izazove u budućnosti. U budućnosti bi istraživanje trebalo proširiti i na ostale dionike poput medicinskih sestara i tehničara kako bi se dobio cjeloviti uvid u korištenje umjetne inteligencije u medicinskoj skrbi. Istraživanje je provedeno 2021. godine kada je značajno manji broj ljudi imao svakodnevni doticaj s alatima koji počivaju na umjetnoj inteligenciji te bi bilo korisno ponoviti istraživanje s nekoliko godina odmaka.

5. Zaključak

Umjetna inteligencija u velikoj se mjeri koristi danas u zdravstvu, a ima još veći potencijal dodatno ući i u druge oblike prevencije, dijagnostike i liječenja, kao i obrade zdravstvenih podataka i upravljanja javnozdravstvenim rizicima. No rezultati ovoga istraživanja ukazuju na to da se puni potencijal umjetne inteligencije može ostvari tek u suradnji s liječnikom koji mora biti osposobljen i informiran kako bi koristio umjetnu inteligenciju kao isključivi alat koji će mu pomoći u učinkovitijem i bržem donošenju odluka, a ne usmjeravati razvoj umjetne inteligencije prema samostalnom funkcioniranju bez intervencije i konačne odluke liječnika.

Literatura:

1. Reyes M, Meier R, Pereira S, Silva CA, Dahlweid F, Von Tengg-Kobligk H i sur. On the interpretability of artificial intelligence in radiology: Challenges and opportunities. Radiol Artif Intell. 2020;2(3):e190043. doi: 10.1148/ryai.2020190043.
2. Mehrizi MHR, Van Ooijen P, Homan M. Applications of artificial intelligence (AI) in diagnostic radiology: a technography study. Eur Radiol. 2021;31(4):1805–1811.
3. Kalani M, Anjankar A. Revolutionizing neurology: The role of artificial intelligence in advancing diagnosis and treatment. Cureus. 2024;16(6):e61706.
4. Bajaj T, Koyner JL. Artificial intelligence in acute kidney injury prediction. Adv Chronic Kidney Dis. 2022;29(5):450–460. doi: 10.1053/j.ackd.2022.07.009.
5. Salinas MP, Sepúlveda J, Hidalgo L, Peirano D, Morel M, Uribe P i sur. A systematic review and meta-analysis of artificial intelligence versus clinicians for skin cancer diagnosis. NPJ Digit Med. 2024;7(1):125.
6. Dlamini Z, Francies FZ, Hull R, Marima R. Artificial intelligence (AI) and big data in cancer and precision oncology. Comput Struct Biotechnol J. 2020;18:2300–2311.
7. Amisha Malik P, Pathania M, Rathaur VK. Overview of artificial intelligence in medicine. J Family Med Prim Care. 2019;8(7):2328–2331.
8. Giordano C, Brennan M, Mohamed B, Rashidi P, Modave F, Tighe P. Accessing artificial intelligence for clinical decision-making. Front Digit Health. 2021;3:645232.
9. Khosravi M, Zare Z, Mojtabaeian SM, Izadi R. Artificial intelligence and decision-making in healthcare: A thematic analysis of a systematic review of reviews. Health Serv Res Manag Epidemiol. 2024;11:23333928241234863.
10. Alowais SA, Alghamdi SS, Alsuhebany N, Alqahtani T, Alshaya AI, Almohareb SN i sur. Revolutionizing healthcare: the role of artificial intelligence in clinical practice. BMC Med Educ. 2023;23(1):689.
11. Kim HE, Kim HH, Han BK, Kim KH, Han K, Nam H i sur. Changes in cancer detection and false-positive recall in mammography using artificial intelligence: a retrospective, multireader study. Lancet Digit Health. 2020;2(3):e138–e148.
12. Brey PAE. Anticipatory ethics for emerging technologies. Nanoethics. 2012;6:1–13.
13. York E, Conley SN. Creative anticipatory ethical reasoning with scenario analysis and design fiction. Sci Eng Ethics. 2020;26(6),2985–3016.
14. Narayanan K, Bakshi A. History and future of digital health in the world and India [Internet]. 2021. [pristupljeno 10. 1. 2025.]. Dostupno na: https://itihaasa.com/public/pdf/History_and_Future_of_Digital_Health_in_the_World_and_India.pdf?v=1.1
15. Vollmar HC, Ostermann T, Redaèlli M. Using the scenario method in the context of health and health care – a scoping review. BMC Med Res Methodol. 2015;15:89.
16. Merriam SB. Qualitative research: A guide to design and implementation. San Francisco: John Wiley & Sons Inc.; 2009.
17. Čartolovni A, Malešević A, Poslon L. Critical analysis of the AI impact on the patient-physician relationship: A multi-stakeholder qualitative study. Digital Health. 2023;9:20552076231220833.
18. Malešević A, Kolesárová M, Čartolovni A. Encompassing trust in medical AI from the perspective of medical students: a quantitative comparative study. BMC Med Ethics. 2024;25(1):94. doi: 10.1186/s12910-024-01092-2.
19. MacIntyre MR, Cockerill RG, Mirza OF, Appel JM. Ethical considerations for the use of artificial intelligence in medical decision-making capacity assessments. Psychiatry Res. 2023;328:115466.