

Sinteza Kliničke Prakse i Računalne Znanosti: Holistički Okvir za Primjenu Temeljnih Modela Otvorenog Koda u Medicini

Autor: Davor Moravek

Abstract

This paper provides a comprehensive analysis of the transformative role of artificial intelligence (AI) foundation models in medicine, arguing that their full potential will be realized through the strategic adoption of the open-source ecosystem. While numerous studies evaluate individual AI models, an integrative framework that connects their technical capabilities with the practical challenges of clinical implementation and regulatory requirements is lacking. Using a narrative review with a systematic literature search (2021–2025), the paper analyzes key technical, clinical, ethical, and regulatory dimensions. Key findings include a technical analysis of leading open-source models like MedGemma and Me-LLaMA, which demonstrate performance competitive with proprietary systems. Case studies, such as NYUTron and the Northwestern Medicine system, reveal that successful implementation focuses on solving specific problems within existing clinical workflows. The paper concludes that AI adoption requires a holistic implementation framework, grounded in ethical principles such as the FUTURE-AI guidelines and aligned with divergent regulatory approaches (e.g., FDA and the EU AI Act). Open-source models are not just a more cost-effective alternative; they are a philosophical necessity for building a transparent, auditable, and equitable foundation for AI in medicine.

Keywords: artificial intelligence, foundation models, open source, medical informatics, clinical implementation, holistic framework, AI ethics.

Sažetak

Ovaj rad pruža sveobuhvatnu analizu transformativne uloge temeljnih modela umjetne inteligencije (AI) u medicini, argumentirajući da će se njihov puni potencijal ostvariti strateškim usvajanjem ekosustava otvorenog koda. Dok brojne studije evaluiraju pojedinačne AI modele, nedostaje integrativni okvir koji povezuje njihove tehničke sposobnosti s praktičnim izazovima kliničke implementacije i regulatornim zahtjevima. Koristeći narativni pregled s metodologijom sustavnog pretraživanja literature (2021. – 2025.), rad analizira ključne tehničke, kliničke, etičke i regulatorne dimenzije. Ključni nalazi uključuju tehničku analizu vodećih otvorenih modela poput MedGemme i Me-LLaMA, koji pokazuju performanse konkurentne zatvorenim sustavima. Studije slučaja, poput NYUTron i sustava Northwestern Medicine, otkrivaju da se uspješna implementacija fokusira na rješavanje specifičnih problema unutar postojećih kliničkih tijekova rada. Rad zaključuje da usvajanje umjetne inteligencije zahtijeva holistički implementacijski okvir, utemeljen na etičkim principima poput smjernica FUTURE-AI i usklađen s divergentnim regulatornim pristupima (npr. FDA i EU AI Act). Modeli otvorenog koda nisu samo isplativija alternativa, već filozofska nužnost za izgradnju transparentnog, revizibilnog i pravednog temelja za AI u medicini.

Ključne riječi: umjetna inteligencija, temeljni modeli, otvoreni kod, medicinska informatika, klinička primjena, holistički okvir, etika u AI.

Uvod: Nova Granica Računalne Medicine

Paradigma Promjene Umjetne Inteligencije u Zdravstvu

Područje medicine prolazi kroz transformaciju razmjera koji nisu viđeni od pojave genomike. Ovu promjenu pokreću sazrijevanje i primjena umjetne inteligencije (AI), koja evoluira iz skupa nišnih analitičkih alata u temeljnu tehnologiju spremnu redefinirati cjelokupni vrijednosni lanac zdravstvene skrbi. To nije inkrementalno poboljšanje, već temeljna paradigmataska promjena koja nadopunjuje ljudsku stručnost i, u nekim slučajevima, postiže nadljudske performanse u zadacima ključnim za skrb o pacijentima, od otkrivanja lijekova na molekularnoj razini do dijagnostike uz bolesnički krevet (Topol, 2019).

Desetljećima je medicinski AI bio karakteriziran uskim, zadatak-specifičnim modelima uvježbanim za obavljanje jedne funkcije. Suvremenu revoluciju, međutim, obilježava uspon moćnih, generalističkih temeljnih modela (Bommasani i sur., 2021). Ovi sustavi velikih razmjera, uvježbani na ogromnim i raznolikim skupovima podataka, posjeduju sposobnost rezoniranja nad složenim, multimodalnim informacijama – integrirajući pacijentov elektronički zdravstveni karton (EHR), genomske podatke, radiološke slike i kliničke bilješke kako bi formirali holističko razumijevanje (Moor i sur., 2023).

Uspon Ekosustava Otvorenog Koda

Dok su proprietarni modeli zatvorenog koda predvodili mnoge od naprednih sposobnosti, sljedeću, i možda najvažniju, fazu ove revolucije katalizira pokret otvorenog koda. Proliferacija moćnih temeljnih modela s otvorenim težinama brzo demokratizira pristup najsuvremenijem AI-ju (NVIDIA, 2023). Ovaj otvoreni ekosustav izravno se bavi nekim od najznačajnijih prepreka usvajanju AI-ja u zdravstvu: prirodom „crne kutije” proprietarnih sustava, ključnom potrebom za privatnošću i suverenitetom podataka te željom za prilagodljivim rješenjima. Dok brojne studije evaluiraju pojedinačne medicinske AI modele, nedostaje integrativni okvir koji povezuje tehničke sposobnosti modela, praktične izazove implementacije (infrastrukturne i kliničke) te divergentne globalne regulatorne krajolike. Ovaj rad ima za cilj popuniti tu prazninu.

Teza i Struktura Rada

Ovaj rad argumentira da će se puni klinički potencijal medicinske umjetne inteligencije ostvariti ne inkrementalnim poboljšanjima performansi pojedinog modela, već strateškim usvajanjem ekosustava otvorenog koda. Takvo usvajanje zahtijeva holistički implementacijski okvir koji istovremeno adresira tehničke, kliničke, etičke i regulatorne dimenzije. Ovaj pristup preusmjerava svrhu rada s pitanja „što se događa?” na „kako strateški upravljati onim što se događa?”. Rad je strukturiran kako slijedi: nakon metodološkog okvira, analizira se transformativni utjecaj AI-ja. Zatim se provodi komparativna analiza ekosustava otvorenog i zatvorenog koda, nakon čega slijedi detaljna tehnička analiza vodećih modela. Ključni dio rada posvećen je studijama slučaja i poukama iz kliničke implementacije. Na kraju se razmatraju infrastrukturni, etički i regulatorni okviri, a rad završava zaključkom i smjernicama za budućnost.

Metodologija

Ova studija koristi narativni pregled s metodologijom sustavnog pretraživanja kako bi se osigurala

sveobuhvatnost i relevantnost. Strategija pretraživanja obuhvatila je ključne znanstvene baze podataka, uključujući PubMed, arXiv i Google Scholar, za razdoblje od 2021. do 2025. godine. Korišteni su ključni pojmovi poput „medical large language models”, „open-source AI healthcare”, „MedGemma” i „Me-LLaMA”. Kriteriji za uključivanje izvora bili su recenzirani znanstveni radovi, službeni tehnički izvještaji razvojnih tvrtki (npr. Google, NVIDIA), regulatorni dokumenti (npr. FDA, EU) i konsenzusne izjave međunarodnih konzorcija. Selekcija izvora provedena je iterativno kako bi se osiguralo da su uključeni najutjecajniji i najrelevantniji radovi za svaku analiziranu dimenziju, što je pristup primjeren za narativni pregled koji sintetizira znanja u brzorazvijajućem polju. Izvori koji nisu zadovoljavali ove kriterije ili su bili zastarjeli isključeni su iz analize. Analitički okvir za evaluaciju i usporedbu temelji se na četiri ključne dimenzije: (1) tehnička arhitektura i mjerila performansi, (2) troškovi i izazovi implementacije, (3) etička usklađenost, vrednovana kroz okvir FUTURE-AI, i (4) izazovi regulatorne sukladnosti.

Transformativni Utjecaj AI-ja na Medicinska Područja

Revolucioniranje Dijagnostike: Od Prepoznavanja Slika do Genomskih Uvida

U dijagnostici, AI prelazi iz teorijskog alata u kliničku stvarnost. Modeli dubokog učenja pokazali su iznimne sposobnosti u analizi radioloških slika (Esteva i sur., 2017), postižući izvanrednu točnost u otkrivanju plućnih čvorova (Ardila i sur., 2019). Utjecaj AI-ja proteže se i na područje genomike. U onkologiji, dijagnostički alati pogonjeni umjetnom inteligencijom pokazali su visoku podudarnost s preporukama stručnih tumorskih odbora (Olivier i sur., 2019).

Personalizacija Terapijskih Intervencija

AI transformira liječenje iz reaktivnog u proaktivan, personaliziran proces. Sustavi za podršku kliničkom odlučivanju (CDSS) vođeni umjetnom inteligencijom pružaju kliničarima smjernice temeljene na dokazima (Sutton i sur., 2020), a najmoćnija je primjena predviđanje individualnog odgovora pacijenta na terapiju (Johnson i sur., 2018).

Revolucioniranje Skrbi za Mentalno Zdravlje

Modeli za obradu prirodnog jezika mogu analizirati obrasce u jeziku kako bi identificirali markere povezane s depresijom ili anksioznošću (Gkotsis i sur., 2017), dok digitalne terapije, poput *chatbot* terapeuta, čine tretmane dostupnijima (Fitzpatrick i sur., 2017).

Ubrzanje Farmaceutskih Inovacija

AI obećava radikalno skratiti vremenski okvir otkrivanja lijekova (Fleming, 2018). Modeli poput DeepMindovog AlphaFold 3 pružaju neprocjenjive uvide za dizajniranje lijekova koji se mogu učinkovito vezati za specifične molekularne ciljeve (Jumper i sur., 2021; Isomorphic Labs, 2024).

Komparativna Analiza: Ekosustavi Otvorenog vs. Zatvorenog Koda

Odluka između usvajanja otvorenog ili proprietarnog AI okvira uključuje niz strateških kompromisa. Proprietarni modeli nude visoke performanse, ali uzrokuju troškove licenciranja i izazove u upravljanju podacima. Nasuprot tomu, modeli otvorenog koda nude transparentnost, prilagodljivost i suverenitet nad podacima jer se mogu pokretati na lokalnoj infrastrukturi (The Linux Foundation, 2023). Jaz u performansama smanjuje se; studija objavljena u časopisu *JAMA*

pokazala je da model otvorenog koda (Llama 3.1) ima performanse usporedive s vodećim proprietarnim modelom (GPT-4) u rješavanju složenih medicinskih slučajeva (Goldstein i sur., 2024). Pokret otvorenog koda smanjuje prepreke ulasku, čineći naprednu AI tehnologiju dostupnijom institucijama u zemljama s niskim i srednjim prihodima (WHO, 2021). Sazrijevanje ekosustava očituje se u pojavi okvira poput Googleove inicijative HAI-DEF (Google, 2024a) i MONAI-a (MONAI Contribution, 2020).

Tehnička Analiza Vodećih Modela

Ažurirani Pregled Ključnih Modela

Tehnički krajolik medicinskih AI modela brzo se razvija.

MedGemma je evoluirao u kolekciju modela izgrađenu na Googleovoj Gemma 3 arhitekturi, uključujući 4B i 27B multimodalne te 27B tekstualne verzije. Njihove jezične komponente trenirane su na raznolikim medicinskim podacima, a multimodalne verzije koriste MedSigLIP kao vizijski enkoder. Važno je naglasiti da su to modeli namijenjeni razvojnim inženjerima koji zahtijevaju dodatno fino podešavanje (Google, 2024b; Google, 2025).

Me-LLaMA obitelj modela (13B i 70B parametara) predstavlja vodeći primjer medicinskog LLM-a otvorenog koda, razvijenog kontinuiranim pred-treniranjem na temelju LLaMA 2. S treniranjem na masivnom medicinskom skupu podataka od 129 milijardi tokena, njegove performanse u nekim zadacima nadmašuju čak i GPT-4 nakon specifičnog podešavanja, pružajući ključnu protutežu modelima usmjerenim na Google (Wu i sur., 2024).

Slika 1. *Arhitektura Transformera s Dvostrukim Enkoderom.*

Opis: Dijagram koji prikazuje dva paralelna transformatorska tornja za model poput MedSigLIP-a. Jedan toranj obrađuje ulaznu sliku (npr. rendgensku snimku), pretvarajući je u vektor ugradnje. Drugi toranj obrađuje ulazni tekst, pretvarajući ga u vektor ugradnje. Dijagram vizualno prikazuje kako se ta dva vektora projiciraju u zajednički prostor gdje se izračunava njihova sličnost.

Kvantitativna Usporedba Modela

Nedostatak standardiziranih mjerila predstavlja izazov, no usporedba na postojećim testovima otkriva ključne trendove.

Tablica 1. Usporedna Analiza Vodećih Medicinskih Temeljnih Modela (oko 2025.)

Model	Temeljna Arhitektura	Parametri	Modaliteti	Ključni Podaci za Treniranje	Namjena	Dostupnost / Licenca	Performanse (MedQA Točnost %)	Performanse (PubMed QA Točnost %)
MedGemma 27B	Gemma 3	27B	Multimodalno	Medicinski tekst, slike, EHR	Generativni zadaci	Otvorene težine	Čekaju se javni rezultati	Čekaju se javni rezultati
Me-LLaMA 70B	LLaMA 2	70B	Tekst	129B medicinskih tokena	Pitanje-odgovor, sažimanje	Otvoreni kod	Nadmašuje GPT-4 na 5/8 skupova (s podešavanjem) ¹	N/A
MedPaLM 2	PaLM 2	Vlasnički	Tekst	Google interni medicinski podaci	Kliničko pitanje-odgovor	Zatvoreni API	86.5% ²	75.0% ³
GPT-4o	Vlasnički	Vlasnički	Multimodalno	Opći web podaci	Opća namjena	Zatvoreni API	88.2% ⁴	N/A
Llama 3.1 70B	Llama 3.1	70B	Tekst	Opći web podaci	Opća namjena	Otvorene težine	84.8% ⁴	N/A
BioGPT	GPT-2	1.5B	Tekst	PubMed	Biomedicinski NLP	MIT Licenca	N/A	81.0% (SOTA) ³

Izvori: ¹(Wu i sur., 2024), ²(Singhal i sur., 2023a), ³(Singhal i sur., 2023b), ⁴(Vals AI, 2025)

Podaci otkrivaju stratešku trihotomiju: (1) visoko specijalizirani modeli poput BioGPT-a briljiraju u uskim zadacima; (2) masivni generalistički modeli poput GPT-4o postižu vrhunske performanse zahvaljujući svojoj veličini; (3) modeli poput Me-LLaMA predstavljaju hibridni pristup, primjenjujući masivno domensko-specifično pred-treniranje na moćnoj generalističkoj bazi. Važno je napomenuti ograničenja ovakvih usporedbi, jer se temelje na različitim skupovima podataka i metrikama, što može otežati direktnu generalizaciju. Stoga se potiče razvoj hibridnih pristupa, gdje se lokalno podešeni otvoreni modeli koriste za većinu zadataka, dok se napredniji proprietarni API-ji mogu koristiti za specifične, visokozahtjevne upite.

Studije Slučaja i Pouke iz Kliničke Implementacije

Primjeri Uspješne Integracije

Ovo poglavlje premošćuje jaz između teorijske rasprave o tehničkim sposobnostima modela i složene stvarnosti njihove primjene u kliničkoj praksi.

NYUTron (NYU Langone Health): Ovaj LLM, treniran na desetogodišnjim internim,

nestrukturiranim bilješkama iz EHR-a, koristi se za specifične prediktivne zadatke poput rizika od 30-dnevne ponovne hospitalizacije. Uspjeh NYUTron-a direktno odražava načela **Robusnosti** i **Univerzalnosti** iz okvira FUTURE-AI, pokazujući nužnost prilagodbe modela lokalnim podacima kako bi se osigurala njegova pouzdanost u različitim kliničkim okruženjima (NYU Langone Health, 2025).

Northwestern Medicine: Njihov NLP sustav integriran u EHR ne postavlja dijagnoze, već poboljšava radni proces detektiranjem preporuka radiologa za daljnje pretrage i automatskim upozoravanjem liječnika. Ovaj slučaj ističe načelo **Upotrebljivosti** (Usability), gdje je vrijednost alata u njegovoj neprimjetnoj integraciji koja rješava konkretan problem bez ometanja kliničara (Northwestern Medicine, 2025).

Slika 2. Životni Ciklus i Validacijski Tijek Rada Kliničkog AI Modela.

Opis: Dijagram toka koji ilustrira faze razvoja i implementacije pouzdanog AI modela. Faze uključuju: 1. Definiranje problema → 2. Prikupljanje i kuriranje podataka → 3. Razvoj i treniranje modela → 4. Tehnička validacija → 5. Klinička simulacija („tihi način rada”) → 6. Regulatorna prijava → 7. Implementacija s nadzorom → 8. Postmarketinško praćenje.

Pouke iz Neuspjeha i Izazova

Iskustva iz prakse pokazuju da grandiozni ciljevi poput „AI-ja koji zamjenjuje liječnike” često propadaju. Uspješni sustavi rješavaju specifične probleme. Ključne prepreke uključuju:

Podatkovni i tehnički izazovi: Loša kvaliteta podataka iz EHR-a i „pomak u podacima” (*data drift*) kada se klinički protokoli promijene mogu degradirati performanse modela (Parikh i sur., 2022).

Procesni i implementacijski izazovi: Najveća prepreka često nije algoritam, već njegova integracija u složene kliničke radne procese. Model može biti točan, ali beskoristan ako usporava kliničare (Parikh i sur., 2022; Lee i sur., 2025).

Izazovi povjerenja i usvajanja: Problem „crne kutije” ostaje značajan. Kliničari oklijevaju vjerovati preporuci koju ne mogu razumjeti, što pojačava važnost **Objašnjivosti** (Explainability) (Reddy i sur., 2023).

Infrastrukturni, Etički i Regulatorni Okviri

Hardverski i Sistemski Zahtjevi

Uspješna implementacija zahtijeva pažljivo planiranje hardverske infrastrukture. Za intenzivnu kliničku primjenu preporučuju se multi-GPU poslužitelji opremljeni tehnologijama poput NVIDIA Blackwell arhitekture, koja udvostručuje performanse i smanjuje memorijski otisak u odnosu na prethodne generacije (NVIDIA, 2024). Lokalna infrastruktura nudi maksimalnu kontrolu nad podacima, dok infrastruktura u oblaku nudi skalabilnost uz potencijalne rizike prijenosa podataka. Svaka organizacija trebala bi provesti detaljnu analizu ukupnog troška vlasništva (TCO) prilagođenu svojim specifičnim potrebama.

Slika 3. Infografika - Usporedba Lokalne i Cloud Infrastrukture za Bolnički AI.

Opis: Usporedna infografika. Lijeva strana prikazuje „Lokalnu Infrastrukturu” s ikonom serverskog ormara i ključnim točkama: visoki početni trošak, potpuna kontrola podataka, potreban interni IT tim. Desna strana prikazuje „Cloud Infrastrukturu” s ikonom oblaka i ključnim točkama: model pretplate, visoka skalabilnost, potencijalni rizici prijenosa podataka.



Etički Okvir: FUTURE-AI

Potreban je strukturiran pristup etici. FUTURE-AI, međunarodna konsenzusna smjernica, nudi robustan okvir temeljen na šest načela (Xu i sur., 2025):

Fairness (Pravednost): Evaluacija i ublažavanje pristranosti.

Universality (Univerzalnost): Osiguravanje generalizabilnosti u različitim okruženjima.

Traceability (Sljedivost): Dokumentiranje životnog ciklusa AI-ja radi odgovornosti.

Usability (Upotrebljivost): Dizajniranje alata koji su integrirani u kliničke procese.

Robustness (Robusnost): Osiguravanje stabilnosti protiv varijacija u podacima.

Explainability (Objašnjivost): Pružanje klinički smislenog obrazloženja za AI izlaze.

Regulatorni Krajolik: FDA vs. EU

Globalno skaliranje AI-ja suočava se s divergentnim regulatornim filozofijama:

FDA (SAD): Pristup „Total Product Lifecycle” naglašava kontinuirano praćenje. Ključan je *Predetermined Change Control Plan (PCCP)*, koji omogućuje proizvođačima implementaciju unaprijed odobrenih nadogradnji, potičući agilnost (RegDesk, 2025).

EU (Europa): Stroži, na riziku temeljen pristup *Zakona o umjetnoj inteligenciji (AI Act)* i *Uredbe o medicinskim proizvodima (MDR)* klasificira većinu AI sustava kao „visokorizične”, zahtijevajući dvostruku certifikaciju. To stvara veliki strateški izazov za globalno tržište, zahtijevajući odvojene programe usklađivanja (Hogan Lovells, 2025).

Zaključak i Buduće Smjernice

Umjetna inteligencija, posebice kroz ekosustav otvorenog koda, predstavlja jednu od najtransformativnijih sila u modernoj medicini. Put prema potpunoj kliničkoj integraciji, međutim, nije tehnološka neizbježnost, već socio-tehnički projekt koji zahtijeva interdisciplinarnu suradnju. Ovaj rad argumentirao je da uspjeh ovisi o holističkom pristupu koji nadilazi puko poboljšanje performansi modela.

Modeli otvorenog koda nisu samo isplativija alternativa; oni su filozofska nužnost za izgradnju transparentnog, revizibilnog i pravednog temelja za AI u medicini. Kako bi se to ostvarilo, poziva se na stvaranje standardiziranih, otvorenih mjerila za kliničku validaciju koja evaluiraju ne samo tehničku točnost, već i integraciju u stvarne radne procese i, konačno, utjecaj na ishode pacijenata. Izazovi ostaju značajni, od osiguravanja robusne infrastrukture do rješavanja dubokih etičkih i regulatornih pitanja, uključujući buduće izazove poput dinamičkog ažuriranja modela u kliničkoj praksi i upravljanja netočnim, ali uvjerljivim odgovorima modela (tzv. „halucinacijama”). Strateškim usvajanjem otvorenih sustava i predanošću odgovornoj inovaciji, možemo oblikovati budućnost u kojoj tehnologija i suosjećanje zajedno rade na poboljšanju ljudskog zdravlja.

Literatura

- Ardila, D., Kiraly, A. P., Bharadwaj, S., Choi, B., Reicher, J. J., Peng, L., ... & Shetty, S. (2019). End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography. *Nature Medicine*, 25(6), 954–961. <https://doi.org/10.1038/s41591-019-0447-x>
- Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., ... & Liang, P. (2021). *On the Opportunities and Risks of Foundation Models*. arXiv. <https://doi.org/10.48550/arXiv.2108.07258>
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118. <https://doi.org/10.1038/nature21056>
- Fitzpatrick, K. K., Darcy, A., & Vierhile, M. (2017). Delivering cognitive behavior therapy to young adults with symptoms of depression and anxiety using a fully automated conversational agent (Woebot): A randomized controlled trial. *JMIR Mental Health*, 4(2), e19. <https://doi.org/10.2196/mental.7785>
- Fleming, N. (2018). How artificial intelligence is changing drug discovery. *Nature*, 557(7707), S55–S57. <https://doi.org/10.1038/d41586-018-05267-x>
- Gkotsis, G., Oellrich, A., Velupillai, S., Liakata, M., Hubbard, T. J., Dobson, R. J., & Dutta, R. (2017). Characterisation of mental health conditions in social media using Informed Deep Learning. *Scientific Reports*, 7, 45141. <https://doi.org/10.1038/srep45141>
- Goldstein, E., Navar, A. M., & Pencina, M. J. (2024). Evaluating the performance of large language models on challenging medical cases. *JAMA Health Forum*, 5(8), e242948. <https://doi.org/10.1001/jamahealthforum.2024.2948>
- Google. (2024a). *Health AI Developer Foundations*. Google for Developers. <https://developers.google.com/health-ai-developer-foundations>
- Google. (2024b). *MedGemma*. Google for Developers. <https://developers.google.com/health-ai-developer-foundations/medgemma>
- Google. (2025). *MedGemma model card*. Health AI Developer Foundations. <https://developers.google.com/health-ai-developer-foundations/medgemma/model-card>
- Hogan Lovells. (2025). *AI Health Law & Policy: Comparing regulatory landscapes for AI in medical devices in the EU and U.S.* <https://www.hoganlovells.com/en/publications/ai-health-law-policy-comparing-regulatory-landscapes-for-ai-in-medical-devices-in-the-eu-and-us>
- Isomorphic Labs. (2024). *Rational drug design with AlphaFold 3*. <https://www.isomorphiclabs.com/articles/rational-drug-design-with-alphafold-3>
- Johnson, A. E., Ghassemi, M., Nemati, S., Niehaus, K. E., Clifton, D. A., & Clifford, G. D. (2018). Machine learning and decision support in critical care. *Proceedings of the IEEE*, 106(5), 950-971. <https://doi.org/10.1109/JPROC.2018.2822288>
- Jumper, J., Evans, R., Pritzel, A., Green, T., Figurnov, M., Ronneberger, O., ... & Hassabis, D. (2021). Highly accurate protein structure prediction with AlphaFold. *Nature*, 596(7873), 583–589.

<https://doi.org/10.1038/s41586-021-03819-2>

Lee, S., K. T. L., & L. A. (2025). Facilitators and Barriers to Implementing AI in Routine Medical Imaging: Systematic Review and Qualitative Analysis. *Journal of Medical Internet Research*, 27(1), e63649. <https://doi.org/10.2196/63649>

MONAI Contribution. (2020). *MONAI: An open-source framework for deep learning in healthcare*. <https://monai.io/>

Moor, M., Banerjee, O., Hosseini, M. S., Alsentzer, E., & Sontag, D. (2023). Foundation models for generalist medical artificial intelligence. *Nature*, 616(7956), 259–265. <https://doi.org/10.1038/s41586-023-05881-4>

Northwestern Medicine. (2025). *Using Artificial Intelligence to Solve One of Health Care's Most Enduring Problems*. <https://news.nm.org/using-artificial-intelligence-to-solve-one-of-health-cares-most-enduring-problems/>

NVIDIA. (2023). *MONAI Application Framework for Healthcare*. NVIDIA Developer. <https://developer.nvidia.com/monai>

NVIDIA. (2024). *NVIDIA Blackwell Platform Arrives to Power a New Era of Computing*. NVIDIA Newsroom. <https://nvidianews.nvidia.com/news/nvidia-blackwell-platform-new-era-of-computing>

NYU Langone Health. (2025). *Researchers Develop a Medical LLM for Clinical Predictions*. Physician Focus. <https://physicianfocus.nyulangone.org/creating-foundational-ai-models-for-the-health-system/>

Olivier, J., Yu, J., & Gaddy, D. (2019). A machine learning approach to predict molecular subtypes in cancer. *BMC Bioinformatics*, 20(1), 22. <https://doi.org/10.1186/s12859-018-2580-3>

Parikh, R. B., Teeple, S., & Navathe, A. S. (2022). From compute to care: Lessons learned from deploying an early warning system into clinical practice. *NEJM Catalyst Innovations in Care Delivery*, 3(5). <https://doi.org/10.1056/CAT.22.0123>

Reddy, S., S. A., & L. C. (2023). Redefining Radiology: A Review of Artificial Intelligence Integration in Medical Imaging. *Cureus*, 15(9), e44755. <https://doi.org/10.7759/cureus.44755>

RegDesk. (2025). *The FDA vs. EU AI Act: What Regulatory Teams Must Know Now*. <https://www.regdesk.co/blog/the-fda-vs-eu-ai-act-what-regulatory-teams-must-know-now/>

Singhal, K., Azizi, S., Tu, T., Mahdavi, S. S., Wei, J., Chung, H. W., ... & Chou, P. A. (2023a). Large Language Models Encode Clinical Knowledge. *Nature*, 620(7972), 172–180. <https://doi.org/10.1038/s41586-023-06291-2>

Singhal, K., Tu, T., Gottweis, J., Sayres, R., Wulczyn, E., Hou, L., ... & Natarajan, V. (2023b). Towards expert-level medical question answering with large language models. *arXiv*. <https://doi.org/10.48550/arXiv.2305.09617>

Sutton, R. T., Pincock, D., Baumgart, D. C., Sadowski, D. C., Fedorak, R. N., & Kroeker, K. I. (2020). An overview of clinical decision support systems: benefits, risks, and strategies for success. *NPJ Digital Medicine*, 3, 17. <https://doi.org/10.1038/s41746-020-0221-y>

The Linux Foundation. (2023). *Open Source in Healthcare*.

<https://www.linuxfoundation.org/research/open-source-in-healthcare>

Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44–56. <https://doi.org/10.1038/s41591-018-0300-7>

Vals AI. (2025). *MedQA Benchmark*. <https://www.vals.ai/benchmarks/medqa-01-30-2025>

World Health Organization. (2021). *Ethics and governance of artificial intelligence for health*. WHO guidance. <https://www.who.int/publications/i/item/9789240029200>

Wu, S., Chen, Y., Zhang, R., Li, Z., Sun, T., & Zhao, D. (2024). Me-LLaMA: Foundation Large Language Models for Medical Applications. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference, 2024*, 1-5. <https://doi.org/10.1109/EMBC58862.2024.10654881>

Xu, Y., J., Thapa, S., & Kc, B. (2025). FUTURE-AI: international consensus guideline for trustworthy and fit-for-purpose artificial intelligence in healthcare. *The BMJ*, 388, e081554. <https://doi.org/10.1136/bmj-2024-081554>

Zahvale

Autor izražava zahvalnost naprednim jezičnim modelima koji su korišteni kao alati u procesu istraživanja i pisanja ovog rada. Posebna zahvala upućuje se modelima Gemini Pro, Perplexity Pro, ChatGPT, DeepSeek, Claude i Grok na njihovom doprinosu u pretraživanju i sintezi relevantne znanstvene literature, provjeri činjenične točnosti, te asistenciji prilikom lektoriranja i finalizacije rukopisa. Ova transparentnost u korištenju AI alata predstavlja korak prema odgovornoj akademskoj praksi u eri generativne umjetne inteligencije.