



The CLEAN PAPER

WHAT THE PAPER SAYS · WHAT IT DOESN'T · WHY IT MATTERS

AI agent samostalno je obrađivao cijele slučajeve pacijenata — u simulatoru, na starim kartonima

MIRA je nova vrsta medicinske umjetne inteligencije: umjesto odgovora na jedno pitanje, obrađuje cijeli slučaj unutar simuliranog bolničkog kartona — uzima anamnezu, naručuje i čita pretrage, dolazi do dijagnoze i piše naloge. Na 574 retrospektivna slučaja iz javne baze, kroz osam unaprijed odabranih dijagnoza, autori navode da je nadmašila liječnike u dijagnostičkoj točnosti i donosila odluke koje su uglavnom bile usklađene sa smjernicama i sigurne u pogledu lijekova. Svaka ograda u toj rečenici važna je: radila je u sandboxu na starim kartonima i samo u tekstu; velik dio prednosti došao je kod stanja s jasnim rezultatima pretraga; naručivala je otprilike dvostruko više krvnih pretraga od liječnika; a nekoliko ishoda ocjenjivano je prema onome što je izvorni karton zabilježio. Stvarni napredak je agent koji djeluje kroz cijeli tijek rada — ne dokaz da stroj sada dijagnosticira bolje od liječnika. Autori to i sami kažu: generalizacija, sigurnost i upravljanje još zahtijevaju prospektivne studije u stvarnom svijetu.

Written by Lucio Vaglio · Cross-checked by Vera Rubin · Edited by Michele Renda · Figures by Laura Nesso and Nova Vela · AI-assisted, human-reviewed

Paper: *Towards autonomous medical artificial intelligence agents*, Dyke Ferber, Lars Hilgers, Christiane Höper and colleagues; senior author Jakob Nikolas Kather, *Nature* (2026) · DOI: 10.1038/s41586-026-10675-5

Odgovoriti na pitanje nije isto što i voditi cijeli slučaj

Većina priča o medicinskoj umjetnoj inteligenciji govori o modelu koji *odgovara*. Date mu kliničku vinjetu ili ispitno pitanje, a on vrati dijagnozu ili odlomak savjeta i postigne dobar rezultat. Korisno, ali usko: pametan konzultant koji nikada ne dodirne karton.

MIRA je napravljena za nešto drugo, a upravo je ta razlika stvarna novost. Umjesto odgovora na jedno pitanje, obrađuje cijeli slučaj: čita pacijentov karton, odlučuje koje podatke iz anamneze još treba, naručuje laboratorijske, slikovne i mikrobiološke pretrage, čita rezultate, sužava diferencijalnu dijagnozu i zatim piše naloge koji slijede — recepte, prijam, upućivanje na operaciju. To čini izvodeći radnje *unutar* elektroničkog zdravstvenog kartona, poput kliničara, umjesto da samo proizvodi slobodan tekst koji bi čovjek morao prepisati.

To je stvaran korak: od sustava koji savjetuje prema sustavu koji djeluje kroz cijeli tijek rada. I upravo je to vrsta koraka koja se u medijskom izvještavanju lako spljošti u „AI nadmašuje liječnike”. Zato vrijedi precizno reći što je testirano i gdje.

Verzija u jednoj rečenici: MIRA je samostalno obrađivala cijele slučajeve i na ovom benchmarku nadmašila liječnike u dijagnostičkoj točnosti — ali učinila je to u sandboxu, na retrospektivnim kartonima, kroz osam unaprijed odabranih dijagnoza, komunicirajući samo tekstom, a velik dio prednosti ostvarila je kod stanja s najjasnijim rezultatima pretraga. Napredak je stvaran. Rezultat na ljestvici nije ambulantna.

MIRA showed a workflow capability, not a clinic verdict

A sandboxed EHR lets an agent act through a whole retrospective case. It is still not a real patient trial.

DEMONSTRATED

- end-to-end case work in a sandboxed EHR
- history, tests, differential diagnosis, orders
- 574 retrospective MIMIC-IV cases
- 8 pre-selected diagnoses
- higher diagnostic accuracy on this benchmark

NOT DEMONSTRATED

- real patients or live hospital deployment
- conditions beyond the eight-target set
- an equally informed head-to-head comparison
- freedom from public-data contamination
- safety and governance for clinical use

A capability shown in a sandbox -- not a diagnostician proven in a clinic.

The figure separates the workflow result from the deployment claim.

MIRA je pokazala sposobnost vođenja cijelog tijeka rada unutar sandboxiranog EHR-a. Nije pokazala kliničku uporabu u stvarnom svijetu, široku dijagnostičku pokrivenost ni poštenu usporedbu s liječnicima koji raspolažu jednakom količinom informacija.

Što su autori napravili

MIRA — Medical Intelligence for Reasoning and Action — autonomni je agent izgrađen na OpenAI-jevim modelima: dio koji razgovara i djeluje koristi **GPT-4o**, a zaseban korak planiranja koristi OpenAI-jev model za rasuđivanje **o1**. Smješteni su u prilagođeni okvir usklađen sa standardima — izgrađen na HL7 FHIR-u, podatkovnom standardu kojim stvarne bolnice razmjenjuju kartone — s više od osamdeset tisuća mogućih kliničkih radnji. Unutar tog sandboxa MIRA može dohvatiti anamnezu, naručiti i protumačiti laboratorijske, slikovne i mikrobiološke pretrage, izraditi diferencijalnu dijagnozu i formulirati plan liječenja — propisati lijekove, zakazati kirurški zahvat, planirati prijam. Vrijedi odmah istaknuti jednu pojedinost: automatizirani „suci” koji su ocjenjivali MIRINE odgovore i sami su bili GPT-4o — ista obitelj modela koja se testira — pa su autori, nakon što je recenzent upozorio na problem, dodali pregled specijalista s odgovarajućom certifikacijom.

Testni skup potjecao je iz **MIMIC-IV**, velike javno dostupne anonimizirane baze elektroničkih zdravstvenih kartona. Od otprilike 300,000 pacijenata liječenih u Beth Israel Deaconess Medical Centeru između 2008. i 2019., autori su odabrali **574 slučaja pacijenata** kroz **osam ciljnih dijagnoza** — abdominalne patologije i hitna stanja interne medicine, među njima apendicitis, pankreatitis, pneumoniju i infekciju mokraćnog sustava. Za svaki slučaj MIRA je počinjala s ograničenom slikom i korak po korak morala odlučiti što će dalje učiniti — istog oblika kao stvarna obrada, ali izvedena nad kartonom čiji je stvarni završetak već poznat.

Njezina izvedba zatim je uspoređena s liječnicima na istim slučajevima.

Što zapravo znači „autonomni agent u sandboxiranom EHR-u”

Tri riječi ovdje nose mnogo značenja, pa ih vrijedi rastaviti.

Agent znači da sustav nije chatbot koji odgovara na prompt. Izvodi petlju: pogleda trenutačno stanje, odabere radnju (naruči ovu pretragu, zatraži taj podatak iz anamneze), vidi rezultat, odabere sljedeću radnju — sve dok ne dođe do dijagnoze i plana. „Inteligencija” je jezični model; *agentnost* daje okolni softverski okvir koji tekst modela pretvara u dopuštene operacije nad EHR-om i rezultate vraća modelu.

Sandboxirani EHR znači simuliranu, odvojenu kopiju sustava medicinskih kartona, a ne živi bolnički sustav. MIRA može „naručiti” pretragu i dobiti rezultat koji je taj pacijent stvarno imao, jer je slučaj povijesni i odgovor je već zabilježen. Ništa što učini ne dotiče stvarnog pacijenta ni stvarnu kliniku.

Autonomno znači da dovršava slučaj od početka do kraja bez čovjeka u petlji — *unutar sandboxa*. To **ne** znači da je puštena da bez nadzora vodi stvarne pacijente. To su vrlo različite tvrdnje, a testirana je samo prva.

Još jedna stvar o sandboxu, jer ga je lako pogrešno zamisliti: MIRA smije *naručiti* bilo koju pretragu, ali sustav može vratiti rezultat samo ako je ta pretraga **doista bila izvedena** tom pacijentu u stvarnom životu. Zatraži li krvnu pretragu koju je pacijent dobio, vraćaju se

stvarne vrijednosti; zatraži li snimku koju nitko nije napravio, vraća se „N/A — could not be performed”, nikada izmišljena brojka. Isto vrijedi za anamnezu: ako karton ne sadrži ono što MIRA pita, simulirani pacijent jednostavno kaže da ne zna. Dakle, MIRA ne može prizvati jednu odlučujuću pretragu koja nikada nije učinjena — može raditi samo s onime što je stvarna obrada slučaja doista sadržavala.

Ta je razlika važna jer je riječ iz naslova — „autonomno” — upravo ona koju će se najlakše pogrešno pročitati kao drugo značenje.

Što su pronašli

Na benchmarku je **MIRA nadmašila liječnike u dijagnostičkoj točnosti** — ali naslov skriva tri različite brojke koje je lako pomiješati pa ih vrijedi razdvojiti.

Sama, na svih **574 slučaja**, MIRA je navela ispravnu dijagnozu u **88.9%** slučajeva — ocjenjivano prema otpusnoj dijagnozi stvarno zapisanoj za svakog pacijenta u MIMIC-IV. U izravnoj usporedbi s ljudima liječnici nisu obrađivali svih 574 slučaja; obrađivali su zajednički **podskup od 311 slučajeva**, uz iste kartone i alate kojima je raspolagala MIRA. Na tih istih 311 slučajeva MIRA je postigla **87.8%**, a uspoređena je s dvije zasebno okupljene skupine liječnika. Prva je bila **seniorna skupina**: četiri certificirana specijalista sa 7 do 11 godina iskustva, koji su postigli **78.1%**. Druga je bila **skupina mješovitog iskustva**: uglavnom mlađi specijalizanti uz dva specijalista, bliža stvarnoj kadrovskoj slici hitnog prijma, koja je postigla **71.1%**. Isti slučajevi, isti alati — redoslijed je bio AI prvi, iskusni liječnici drugi, mlađa skupina treća. Oprezna formulacija samog rada jest da je MIRA bila „dosljedno jednaka liječnicima, a često ih i nadmašivala” kroz svih osam bolesti.

I odluke nakon dijagnoze uglavnom su se održale: bile su većinom usklađene sa smjernicama, sigurne u pogledu lijekova i primjerene za odluku o prijemu. Autori navode da nije bilo teških pogrešaka u propisivanju kroz pet sigurnosnih kategorija (interakcije lijekova, doziranje kod bubrežne funkcije, alergije, QT-rizik i propisivanje opioda), a recepti su bili ispravni u 467 od 468 slučajeva — uz napomenu da sustav „nije postigao 100% pouzdanost”. Ako se uzme doslovno, to je upečatljiv rezultat: agent vodi cijeli slučaj i završava ispred liječnika u dijagnozi.

Ali *oblik* te pobjede važan je koliko i sama pobjeda. Neovisni stručnjaci koji su čitali rad istaknuli su odakle zapravo dolazi prednost. Na stručnom panelu Science Media Centrea dr. Wei Xing (University of Sheffield) primijetio je da je naslovna brojka — AI nadmašuje liječnike u dijagnostičkoj točnosti — **uglavnom potaknuta stanjima s jasnim rezultatima pretraga**, poput apendicitisa i pankreatitisa, gdje odlučujuća snimka ili laboratorijska vrijednost rješava pitanje. Kod pneumonije i infekcija mokraćnog sustava — dva vrlo česta razloga dolaska u hitnu službu — i AI i liječnici imali su najlošije rezultate, a razlika među njima bila je najmanja.

Postojala je i asimetrija u načinu na koji su dvije strane „igrale”, i ona je vidljiva u brojkama samog rada. MIRA se znatno više oslanjala na laboratorij: koristila je oko **51%** laboratorijskih analita dostupnih u rutinskoj skrbi, naspram otprilike **28%** kod certificiranih liječnika — medijan od sedam dodatnih krvnih parametara po slučaju. Autori pažljivo navode da je to *ispod* rutinske razine u samom

skupu podataka, a ne strategija „naruči sve”, te da nije bilo sustavnog povećanja skupljeg presječnog snimanja. Ipak, više informacija samo po sebi može dati veću dijagnostičku točnost — pa ovo nije sasvim usporedba jednako informiranih sudionika, što je Xing izravno istaknuo. I kliničar koji smije naručiti svaku jeftinu krvnu pretragu bez vaganja cijene, neugode ili kašnjenja izgledao bi preciznije na papiru.

Zašto „pobijedila liječnike” ne znači „bolji liječnik”

Pobjedu na benchmarku lako je previše protumačiti. Tri stvari stoje između „MIRA je postigla viši rezultat” i „MIRA je bolja”.

Prvo, **prema čemu se ocjenjivala**. Profesorica Julie Jacko (University of Edinburgh) primijetila je da je nekoliko ključnih MIRINIH ishoda definirano u odnosu na ono što je zapisano u izvornom skupu podataka — što znači da je sustav nagrađen za **ponavljanje zabilježenog kliničkog ponašanja**, a ne nužno za dokazivanje optimalne skrbi. Povijesni karton postaje ključ odgovora. To je razuman način izgradnje benchmarka, ali mjeri slaganje s onime što je učinjeno, a ne apsolutnu ispravnost. Pošteno prema radu, to najviše pogađa metrike *usklađenosti liječenja* — podudaraju li se MIRINI nalozi s kartonom? — dok se naslovna dijagnostička točnost mjeri prema otpusnoj dijagnozi, što je bliže stvarnom ishodu nego odjeku dokumentacije.

Drugo, već spomenuta **asimetrija informacija**: mnogo više krvnih pretraga (oko 51% dostupnih analita prema 28%) znači i više dokaza. Dio razlike u točnosti vjerojatno je *kupljen* dodatnim informacijama, a ne izveden boljim rasuđivanjem.

Treće, **gdje je sustav radio**. Ovo je bio sandbox na retrospektivnim slučajevima, kroz osam unaprijed odabranih dijagnoza i samo u tekstu. Stvarna klinička procjena, kako je rekao dr. Dominic Oliver (University of Oxford), ne ovisi samo o tome što pacijenti kažu nego i kako to kažu — uz fizikalni pregled, opaženo ponašanje i govor tijela, od čega tekstualni agent koji čita gotov karton ne vidi ništa. Pacijent čiji problem ne pripada jednoj od osam odabranih dijagnoza jednostavno je izvan onoga o čemu ova studija može govoriti.

Recenzenti su istaknuli i tišu brigu: **kontaminaciju podataka**. MIMIC-IV je javan i o njemu se mnogo piše, pa je jezični model treniran na otvorenom internetu možda već vidio radove, rasprave o slučajevima ili same podatke. Dr. Midhun Parakkal Unni (University of Sheffield) izravno je upozorio na to — ako su neki odgovori bili u podacima za treniranje, dio izvedbe je pamćenje, a ne kliničko rasuđivanje, i samo neovisna replikacija može razlikovati jedno od drugoga. Autori taj problem ne umanjuju: pišu da se rezultati „mogu oprezno tumačiti kao moguća gornja granica” i da „mogu precijeniti generalizaciju na druge javne slučajeve” — rad sam postavlja strop vlastitom naslovu.

Ništa od toga MIRU ne čini manje zanimljivom. Samo zahtijeva odmjereno čitanje: na retrospektivnom benchmarku agent koji je mogao djelovati kroz cijeli karton nadmašio je liječnike kod dijagnoza s čistim testovima — dijelom naručujući više pretraga, dijelom slažući se sa zabilježenim kartonom. To je stvarna demonstracija sposobnosti, a ne presuda da strojevi sada dijagnosticiraju bolje od liječnika.

Što ovo ne dokazuje

- **Ne** pokazuje da MIRA radi na stvarnim pacijentima. Svaki slučaj bio je retrospektivan i simuliran; MIRA nikada nije vodila stvarnog pacijenta.
- **Ne** pokazuje da radi izvan osam dijagnoza. Stanja izvan unaprijed odabranog skupa — neuredna, nediferencirana većina medicine — nisu testirana.
- **Ne** pokazuje da je sigurna za uporabu. Sami autori pišu da generalizacija, sigurnost i upravljanje još zahtijevaju prospektivne studije u stvarnom svijetu.
- **Ne** uspostavlja poštenu izravnu usporedbu s liječnicima. MIRA je koristila mnogo više krvnih pretraga (oko 51% dostupnih analita naspram 28%), a nekoliko ishoda liječenja djelomično je ocjenjivano prema povijesnom kartonu umjesto prema neovisnoj najboljoj skrbi.
- **Ne** pokazuje da je rezultat oslobođen pamćenja. Javni podaci MIMIC-IV mogu se preklapati s podacima za treniranje modela, što bi neovisna replikacija morala isključiti.
- **Ne** znači „AI zamjenjuje liječnike”. To je potpora odlučivanju koja može *djelovati* kroz karton; stručni konsenzus je da će se stvarna uporaba odvijati u partnerstvu s kliničarima, koji zadržavaju ovlast i daju sve ono što tekstualni karton izostavlja.

Koliko su dokazi jaki?

Tvrđnju treba podijeliti na dva dijela jer su dokazi za njih vrlo različiti.

Kao demonstracija sposobnosti — da agent temeljen na jezičnom modelu može provesti cijeli klinički slučaj unutar EHR sandboxa, povezati anamnezu, pretrage, dijagnozu i naloge od početka do kraja — rad je doista nov i prilično uvjerljiv. To je novi dio i on zaslužuje pozornost.

Kao tvrdnja o nadmoći — da je MIRA *bolja od liječnika* — dokazi su ograničeni i treba ih oprezno čitati. Vrijede na određenom retrospektivnom benchmarku, na osam dijagnoza, uz asimetriju informacija (više pretraga), ključ odgovora izveden iz povijesnog kartona i stvarnu mogućnost kontaminacije podataka za treniranje. To je dovoljno da se kaže „agent je impresivno radio na ovom benchmarku”. Nije dovoljno za „agent je bolji dijagnostičar od liječnika”, a autori ni ne tvrde to drugo.

Najkorisniji stav nije ni „AI pobjeđuje liječnike” ni „samo igračka”. On glasi: nova vrsta medicinske umjetne inteligencije — ona koja *djeluje* kroz karton umjesto da samo odgovara na pitanja — dobro se pokazala na zahtjevnom retrospektivnom benchmarku i sada se mora dokazati tamo gdje još nije isprobana: na stvarnim, nediferenciranim pacijentima, prospektivno i pod odgovarajućim upravljanjem.

Zašto je to važno

Posljednjih nekoliko godina zanimljivo pitanje u medicinskoj umjetnoj inteligenciji tiho se promijenilo. Nekad je bilo „može li model pogoditi dijagnozu?” — i modeli su sve češće odgovarali da mogu, na

sve čistim testnim skupovima. MIRA označava pomak prema težem pitanju: „može li model *obaviti posao* — prikupiti, naručiti, protumačiti, odlučiti, djelovati — kroz cijeli tijek rada?” To je korisnije i poštenije pitanje jer su upravo u djelovanju i teškoća i rizik.

Zato je okvir priče važan. Refleksni naslov — *AI nadmašuje liječnike* — upire u najmanje nov i najslabije potkrijepljen dio rezultata. Ono doista novo manje je i važnije: agent koji se može kretati kroz cijeli karton. Ako ta sposobnost izdrži provjeru, promijenit će **tijek rada** puno prije nego što promijeni tko njime upravlja. Liječnik nije zamijenjen; naručivanje, tumačenje i praćenje rezultata — tijek rada — mjesto je gdje alat poput ovoga prvo ulazi.

To i teret dokazivanja pomiče u pravom smjeru. Pobjeda na ljestvici retrospektivnih slučajeva razlog je da se provede prospektivno ispitivanje, a ne zamjena za njega. Autori kažu isto. Pošteno čitanje MIRE poziv je na sljedeću studiju — prema standardu koji polje već poznaje: mjeriti na pacijentima, a ne na benchmarkovima.

Sažetak bez ukrasa

MIRA je autonomni AI agent koji djeluje unutar sandboxiranog elektroničkog zdravstvenog kartona: može uzeti anamnezu, naručiti i protumačiti laboratorij, snimanje i mikrobiologiju, doći do dijagnoze i napisati plan liječenja. Testirana na 574 retrospektivna slučaja iz javne baze MIMIC-IV, kroz osam unaprijed odabranih dijagnoza, nadmašila je liječnike u dijagnostičkoj točnosti (88.9% ukupno; 87.8% naspram 78.1% u izravnoj usporedbi) i donosila odluke koje su uglavnom bile usklađene sa smjernicama i sigurne u pogledu lijekova. Ali evaluacija je bila simulacija na starim kartonima i samo u tekstu; velik dio prednosti došao je kod stanja s jasnim rezultatima pretraga; MIRA je koristila mnogo više krvnih pretraga od liječnika (oko 51% dostupnih analiza naspram 28%); nekoliko ishoda liječenja ocjenjivano je prema onome što je izvorni karton zabilježio; a javni skup podataka stvara stvaran rizik kontaminacije podataka za treniranje — što sami autori nazivaju mogućom gornjom granicom svojih brojki. Stvaran napredak je agent koji djeluje kroz cijeli tijek rada umjesto da odgovara na izolirana pitanja. Autori izričito navode da generalizacija, sigurnost i upravljanje još zahtijevaju prospektivne studije u stvarnom svijetu — što je i ispravno čitanje: impresivna demonstracija sposobnosti, a ne dokaz da AI dijagnosticira bolje od liječnika niti sustav spreman za stvarnu ambulantu.

Provjera bez uljepšavanja

Što rad pokazuje: Agent temeljen na jezičnom modelu (MIRA) može provesti cijeli klinički slučaj od početka do kraja unutar sandboxiranog EHR-a — anamneza, pretrage, dijagnoza, nalozi — i na retrospektivnom benchmarku od 574 slučaja kroz osam dijagnoza nadmašiti liječnike u dijagnostičkoj točnosti (88.9% ukupno; 87.8% naspram 78.1% u usporedbi s certificiranim liječnicima), bez teških pogrešaka u lijekovima.

Što je vjerojatno, ali nije dokazano: Da se ta sposobnost pretvara u korist za stvarne, nediferencirane pacijente; da prednost u točnosti odražava bolje rasuđivanje, a ne više naručenih pretraga, slaganje

sa zabilježenim kartonom ili zapamćene javne podatke.

Što ne pokazuje: Da MIRA radi izvan osam dijagnoza; da je sigurna za uporabu; da pobjeđuje liječnike u poštenoj usporedbi s jednakim informacijama; da zamjenjuje kliničare; da su rezultati oslobođeni kontaminacije podataka za treniranje.

Glavna ograničenja: Retrospektivna, simulirana evaluacija samo u tekstu; osam unaprijed odabranih dijagnoza; asimetrija informacija (mnogo više krvnih pretraga — oko 51% dostupnih analita naspram 28%, i to jeftinih krvnih pretraga, ne snimanja); ishodi liječenja dijelom ocjenjivani prema povijesnom kartonu; javni benchmark MIMIC-IV koji je jezični model možda vidio tijekom treniranja — što autori označavaju kao moguću gornju granicu izvedbe.

Koliko povjerenja treba imati opći čitatelj? Visoko da je MIRA stvarna i nova demonstracija sposobnosti — agent koji *djeluje* kroz karton, a ne samo chatbot. Nisko da je *bolji dijagnostičar od liječnika*: ta je tvrdnja ograničena na jedan retrospektivni benchmark i zamagljena većim brojem pretraga, ocjenjivanjem prema kartonu i mogućom kontaminacijom. Zaključak samih autora je pravi — prije nego što ovo znači išta za skrb o pacijentima, potrebna je prospektivna studija u stvarnom svijetu.

Izvori

Ferber et al., Towards autonomous medical artificial intelligence agents, Nature (2026)

<https://doi.org/10.1038/s41586-026-10675-5>

PubMed 42310457 — peer-reviewed abstract

<https://pubmed.ncbi.nlm.nih.gov/42310457/>

Science Media Centre — expert reaction to MIRA and AMIE (2026)

<https://www.sciencemediacentre.org/expert-reaction-to-presentation-of-two-new-medical-ai-models-for->

News-Medical (2026) — illustrates the 'outperforms doctors' framing

<https://www.news-medical.net/news/20260621/Autonomous-medical-AI-outperforms-doctors-in-simulated-EH.aspx>