The CLEAN PAPER

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

هوش مصنوعی در مراقبت اولیه مستندسازی را بهتر کرد، اما بیماران ظرف ۱۴ روز بهتر نشدند

یک کارآزمایی عمل‌گرایانه و خوشه‌ای-تصادفی در ۱۶ مرکز مراقبت اولیهٔ کنیا، ابزار *Consult AI* مبتنی بر *GPT-4o* را در پروندهٔ الکترونیک ۱۰۳ کارشناس بالینی آزمود. میان ۹٬۶۹۱ بیمار، شکست درمانِ داوری‌شده در ۱۴ روز ۲٫۲٪ با *AI* و ۲٫۰٪ بدون آن بود؛ *OR* تعدیل‌شده ۰٫۷۷ با فاصلهٔ اطمینان ۹۵٪ برابر ۰٫۵۵–۱٫۰۸ و *P*=0.13؛ بنابراین سود معناداری نشان داده نشد. ابزار سیگنال ایمنی تازه‌ای ایجاد نکرد، مستندسازی را بهتر کرد و شاید هزینهٔ برخی داروها را کاهش داده باشد. نتیجه نمونهٔ خوبی است از اینکه بهبود فرایند بالینی با بهبود اثبات‌شدهٔ پیامد بیمار یکی نیست.

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

Paper: *Generative AI-enabled clinical decision support system in primary care: a pragmatic, cluster-randomized trial*, Ambrose Agweyu, Paul Mwaniki, Vaishnavi Menon, Robert Korom, Lynda Isaaka, Conrad Wanyama, Xiaoxuan Liu & Bilal A. Mateen (and colleagues), Nature Medicine (2026) · DOI: 6-04503-026-s41591/1038.10

ایمن و مفید بودن با «موثر بودن» یکی نیست

بیشتر تیترهای مربوط به هوش مصنوعی پزشکی از نوع اشتباهی از مطالعه ساخته می‌شوند. یک مدل در سؤال‌های امتحانی نمرهٔ خوبی می‌گیرد یا در هایvignette گزینش‌شده از پزشکان جلو می‌زند و داستان خودش نوشته می‌شود: ماشین برای کلینیک آماده است.

این کارآزمایی کاری دشوارتر و نادرتر انجام داد. ابزار پشتیبان تصمیم‌گیریِ مبتنی بر هوش مصنوعی مولد را وارد مراقبت اولیهٔ واقعی، در مراکز واقعی و کنار بیماران واقعی کرد و پرسشی را مطرح کرد که واقعاً اهمیت دارد: آیا حال بیماران بهتر شد؟

پاسخ صادقانه نه است — دست‌کم نه به شکلی که در ۱۴ روز قابل‌اندازه‌گیری باشد. ابزار هیچ سیگنال ایمنی نشان نداد. کیفیت مستندسازی بالینی را بهتر کرد. شاید حتی بعضی هزینه‌های دارویی را پایین آورده باشد. اما شکست درمان را به‌طور معنادار کاهش نداد و نویسندگان با دقت می‌گویند اگر منفعتی وجود داشته باشد، احتمالاً متوسط است.

این شکست مطالعه نیست. این یعنی مطالعه درست کار کرده. وقتی هوش مصنوعی پزشکی را به‌جای benchmark روی بیمار اندازه بگیریم، شواهد مسئولانه شبیه همین‌اند.

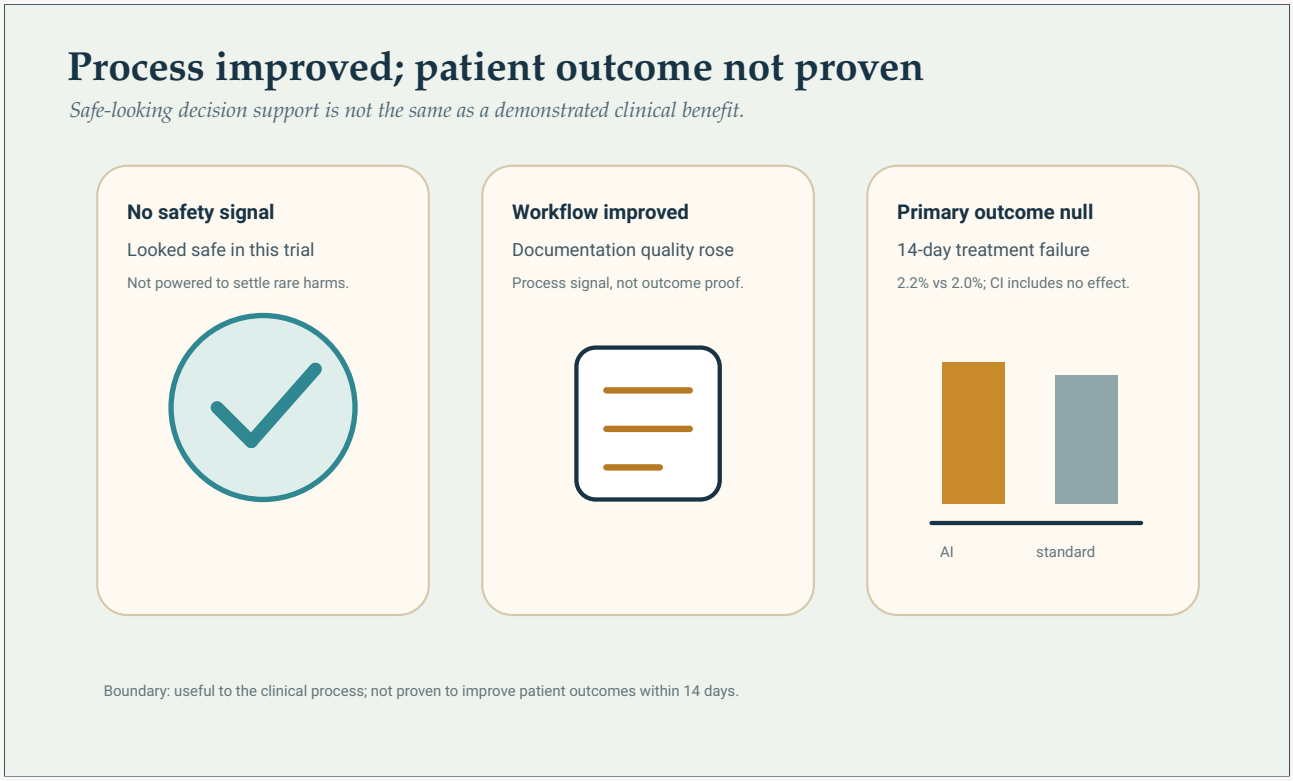

ابزار هیچ سیگنال ایمنی نشان نداد و مستندسازی بالینی را بهتر کرد، اما پیامد ازپیش‌تعیین‌شدهٔ ۱۴روزهٔ بیمار به‌طور معنادار بهتر نشد. کمک به فرایند مراقبت با منفعت اثبات‌شده برای بیمار یکی نیست.

نویسندگان چه کردند

گروه یک کارآزمایی pragmatic و cluster-randomized در **۱۶ مرکز مراقبت اولیه** متعلق به شبکهٔ خصوصی Health Penda در شهرستان‌های Nairobi و Kiambu کنیا اجرا کرد. مراقبت در این مراکز عمدتاً توسط **clinical officerها** — کارکنان بالینی سطح میانی با مدرک سه‌ساله — ارائه می‌شود که اغلب دسترسی آسانی به مشاورهٔ پزشک ارشد ندارند.

واحد تصادفی‌سازی پزشک/کارورز بود، نه بیمار. **۱۰۳ clinical officer** تصادفی شدند: ۵۲ نفر به بازوی مداخله و ۵۱ نفر به کنترل. هر دو بازو از همان پروندهٔ الکترونیک ابری استفاده کردند. بازوی مداخله افزون بر آن **Consult AI** نسخهٔ 0.2 داشت، ابزار پشتیبان تصمیم‌گیری ساخته‌شده روی مدل زبانی بزرگ **GPT-4o از OpenAI** که در همان پرونده تعبیه شده بود. ابزار اطلاعات ثبت‌شده توسط clinician را می‌خواند و می‌توانست مشکلات احتمالی در تشخیص یا برنامهٔ درمان را علامت بزند. اختیار کامل دست clinician بود: می‌توانست پیشنهاد را بپذیرد، تغییر دهد یا نادیده بگیرد.

کدام مدل بود و چرا جزئیات مهم‌اند

مجوز با OpenAI تجاری API طریق از را ۲۰۲۵) مه (نسخهٔ **OpenAI از GPT-4o** که بود **AI Consult 0.2** ابزار اختصاصی الکترونیک پروندهٔ داخل ابزار می‌کرد. اجرا 1.0) temperature) پایین randomness تنظیم و enterprise بود؛ شده نوشته کنیا درمان ملی دستورالعمل‌های با هم‌راستایی برای هایشsystem prompt و داشت قرار EasyClinic کردند. منتشر را prompt کامل متن نویسندگان

چرا این جزئیات را می‌گوییم؟ چون نتیجه دربارهٔ یک سامانهٔ مشخص است — یک نسخهٔ مدل، یک prompt، یک پرونده و یک تنظیم — نه دربارهٔ هاLLM» در پزشکی» به‌طور کلی. خود نویسندگان هم همین نکته را می‌گویند و یافته را *benchmark* زمانی، نه برآورد ثابت توانایی می‌نامند. مدل تازه‌تر، prompt متفاوت یا کلینیکی با دیجیتالی‌شدن کمتر می‌تواند نتیجه را جابه‌جا کند.

دربارهٔ استقلال: OpenAI بعداً حمایت غیرنقدی فراهم کرد (اعتبار رایانش ابری و راهنمایی فنی برای ،(API اما نویسندگان می‌گویند تصمیم استفاده از OpenAI پیش از این پیشنهاد گرفته شده بود و OpenAI در طراحی کارآزمایی، جمع‌آوری داده، تحلیل یا تصمیم به انتشار نقشی نداشت.

بین ۲۲ آوریل و ۱۶ ژوئیهٔ ۲۰۲۵، **۹٬۶۹۱ بیمار** وارد شدند. **پیامد اولیه عمداً بیمارمحور و سخت‌گیرانه بود**: یک ترکیب داوری‌شده توسط متخصص از شکست درمان در ۱۴ روز پس از ویزیت — هیئتی از ،clinicianها بدون اطلاع از بازوی مطالعه، قضاوت کردند آیا هر بیمار پیامد بدی مانند ادامه یا بدترشدن بیماری داشته است. کارآزمایی از پیش ثبت شده بود (Pan-African Clinical Trials Registry 202502499779176).

همین انتخاب طراحی اصل ماجراست. آسان است نشان دهید ابزار AI چیزی را که clinician می‌نویسد تغییر می‌دهد. بسیار سخت‌تر — و مهم‌تر — است نشان دهید آنچه برای بیمار رخ می‌دهد تغییر کرده است.

چه پیدا کردند

پیامد اولیه بهتر نشد. شکست درمان در ۱۰۲ نفر از ۴٬۶۹۳ بیمار (۲٫۲٪) در بازوی AI و ۹۴ نفر از ۴٬۶۵۴ (۲٫۰٪) در کنترل رخ داد. درصد خام کمی در AI بالاتر بود، اما پس از تعدیل نقطه‌برآورد به سوی منفعت متمایل شد: **ratio odds adjusted برابر ۰٫۷۷ بود (95% CI 55.0 تا 08.1، P = 13.0)** — از نظر آماری معنادار نبود. وارونگی میان عدد خام و تعدیل‌شده اشتباه حسابی نیست؛ تعدیل اختلاف میان خوشه‌های clinician را در نظر می‌گیرد. در هر حال فاصلهٔ اطمینان «بدون اثر» را به‌راحتی شامل می‌کند، پس نمی‌توان ادعای منفعت کرد و اثر مطلق هم بسیار کوچک بود.

برای خوانش سادهٔ odds ratio، فاصلهٔ اطمینان و value P در کنار هم، راهنمای نتایج بالینی را ببینید.

هیچ سیگنال ایمنی — در محدودهٔ این مطالعه. هیچ عارضهٔ جدی‌ای مرتبط با ابزار تشخیص داده نشد و بازبینی مستقل سیگنال ایمنی پیدا نکرد. نویسندگان سقف این آرامش را صریح می‌گویند: کارآزمایی برای یافتن آسیب‌های شدید و نادر توان کافی نداشت و چارچوب از پیش‌تعیین‌شدهٔ noninferiority یا ایمنی رسمی نداشت، پس نمی‌تواند ایمنی برای رویدادهای نادر را اثبات کند.

مستندسازی بهتر شد. در میان ۲٬۰۰۰ ویزیت که متخصصان کور بازبینی کردند، های‌clinician استفاده‌کننده از Consult AI در همهٔ حوزه‌های نمره‌گذاری‌شده مستندسازی بهتری داشتند — تشخیص ثبت‌شده، برنامهٔ درمان و کامل‌بودن کلی.

نسخه‌نویسی تقریباً تکان نخورد. اختلاف معناداری در نسخه‌نویسی، از جمله مصرف صحیح آنتی‌بیوتیک، وجود نداشت (adjusted OR 0.86، 95% CI 0.48 تا 1.55). ابزار نرخ نسخه‌کردن آنتی‌بیوتیک را تغییر نداد.

بیماران تفاوتی حس نکردند. در ۸۲۶ بیماری که پرسش‌نامهٔ رضایت را تکمیل کردند، رضایت تقریباً در دو بازو یکسان و زمان مشاوره مشابه بود.

هزینه‌ها کمی رو به پایین اشاره کردند. در تحلیل تعدیل‌شده، هزینهٔ مرتبط با آنتی‌بیوتیک در بازوی AI کمتر بود — احتمالاً به‌دلیل انتخاب داروهای ارزان‌تر، نه نسخه‌های کمتر — و صرفه‌جویی آنتی‌بیوتیک به ازای بیمار ظاهراً از هزینهٔ اجرای ابزار بیشتر بود. نویسندگان این را پیشنهادکننده می‌دانند، نه قطعی؛ حسابداری کامل ownership of cost total خارج از کارآزمایی بود.

خلاصهٔ یک‌خطی خود نویسندگان تمیزترین است: کمک LLM در این محدودیت‌ها ایمن به نظر رسید، اما شکست درمان در ۱۴ روز را کاهش نداد و هر منفعتی احتمالاً متوسط است.

چرا «تفاوت معنادار نبود» به معنی «کار نمی‌کند» نیست

پیامد اولیهٔ null را می‌شود در هر دو جهت بیش‌ازحد خواند. دو نکته جلوی داستان ساده را می‌گیرند.

اول، **کارآزمایی برای اثر بزرگ‌تری از آنچه دید طراحی شده بود.** پیامدهای بد جدی در مراقبت اولیه نادرند — این‌جا حدود ۲٪ — بنابراین جدا کردن منفعت کوچک واقعی از نویز به تعداد بسیار زیادی بیمار نیاز دارد. محاسبات توان post-hoc نویسندگان نشان می‌دهد برای تشخیص اثری به اندازهٔ مشاهده‌شده **کارآزمایی بسیار بزرگ‌تر، در حد بیش از ۱۰۰٬۰۰۰ بیمار** لازم است. نتیجهٔ غیرمعنادار در این حجم، منفعت کوچک واقعی را رد نمی‌کند؛ می‌گوید این مطالعه قادر به تفکیکش نبود.

دوم، **مقایسه تا حدی آلوده شد.** یک خطای پیکربندی برای مدتی به بعضی های‌clinician بازوی کنترل دسترسی به Consult AI داد، و افراد در یک شبکهٔ مشترک با هم حرف می‌زنند و عادت‌ها را از مرز بازوها عبور می‌دهند. هر دو عامل دو گروه را شبیه‌تر می‌کنند و هر اختلاف واقعی را به سمت صفر هل می‌دهند. افزون بر آن، شبکهٔ میزبان از ابتدا استاندارد نسبتاً بالایی داشت، پس جای کمتری برای نمایش بهبود باقی می‌ماند.

هیچ کدام تیتر «جهش بزرگ» را نجات نمی‌دهد. اما خوانش درست را تنظیم‌شده نگه می‌دارد، نه تحقیرآمیز: روی سخت‌ترین و صادقانه‌ترین endpoint، این ابزار در دو هفته به‌طور قابل‌اثبات به بیماران کمک نکرد — در حالی که مستندسازی را واقعاً بهتر کرد و ایمن به نظر رسید.

این مقاله چه چیزی را اثبات نمی کند

- نشان نمی‌دهد AI **پیامد بیمار را بهتر کرد.** در endpoint اصلی ۱۴روزه منفعت معنادار نبود.
- نشان نمی‌دهد AI **بی‌فایده است.** نقطه‌برآورد به نفع آن بود، مستندسازی در همهٔ حوزه‌ها بهتر شد و هزینهٔ دارو رو به پایین رفت؛ نتیجهٔ null با منفعت کوچک واقعی که مطالعه برای تأییدش کوچک بوده سازگار است.
- ثابت نمی‌کند ابزار برای آسیب‌های نادر **ایمن است.** سیگنال ایمنی دیده نشد، اما مطالعه برای تأیید ایمنی رویدادهای شدیدِ کم‌یاب طراحی نشده بود.
- نشان نمی‌دهد AI» از پزشک بهتر است» یا clinician را جایگزین می‌کند. این **پشتیبان تصمیم** است؛ اختیار کامل با clinician ماند.
- خودکار قابل‌تعمیم نیست. کارآزمایی در یک شبکهٔ خصوصی شهری در کنیا بود؛ محیط روستایی، پیرامون‌شهری یا کشورهای پردرآمد ممکن است در هر جهت متفاوت باشند.
- صرفه‌جویی هزینه را تثبیت نمی‌کند. سیگنال هزینه پیشنهادکننده است، نه ارزیابی اقتصادی کامل.

قدرت شواهد چقدر است؟

برای ادعای مرکزی — نبود کاهش اثبات‌شده در آسیب کوتاه‌مدت بیمار — طراحی شواهد قوی است و نتیجه‌گیری به‌درستی فروتنانه. کارآزمایی ،prospective از پیش ثبت‌شده، cluster-randomized با پیامد ترکیبی بیمارمحور و داوری کور، نزدیک به بهترین نوع شاهد واقعی است که برای چنین ابزاری می‌توان جمع کرد. بسیار اطلاعاتی‌تر از نمرهٔ benchmark یا مطالعهٔ vignette است.

برای یافته‌های ثانویه — مستندسازی بهتر، نسخه‌نویسی بدون تغییر، رضایت مشابه، هزینهٔ آنتی‌بیوتیک پایین‌تر — شواهد خوب‌اند اما باید ثانویه خوانده شوند: سیگنال‌های حمایتی، نه تیتر، و همچنان حساس به آلودگی دو بازو و محدودیت تک‌شبکه‌ای.

برای ایمنی، شاهد آرامش‌بخش اما محدود است: سیگنالی پیدا نشد، اما مطالعه برای یافتن آسیب نادر ساخته نشده بود.

مفیدترین موضع نه «کار می‌کند» است و نه «شکست خورد». این است: یک کارآزمایی واقعی و دقیق نشان داد این ابزار AI هیچ سیگنال ایمنی ایجاد نکرد و فرایند مراقبت را بهتر کرد، بدون این که منفعتی برای پیامد بیمار در دو هفته نشان دهد — و برای دیدن منفعت احتمالی به مطالعه‌ای بسیار بزرگ‌تر نیاز است.

چرا مهم است

بحث هوش مصنوعی پزشکی دقیقاً از چنین شواهدی کم دارد. هزاران مقاله وجود دارد که مدل‌ها در امتحان عالی‌اند یا در پرونده‌های مرتب با هاclinician برابری می‌کنند. کارآزمایی pragmatic بزرگ و تصادفی که بپرسد بیمار واقعی بهتر شد بسیار کم است. این یکی از آن‌هاست و روی حقیقت کم‌زرق‌وبرق فرود می‌آید: قبولی در آزمون با کمک کردن به بیمار یکی نیست.

همین شکاف کل داستان است. ابزار می‌تواند واقعاً برای clinician مفید باشد — یادداشت روشن‌تر، قبض داروی کمتر، یک جفت چشم دوم — و در عین حال ظرف دو هفته endpoint سخت بیمار را جابه‌جا نکند. هر دو می‌توانند هم‌زمان درست باشند و نظام سلامت بالغ باید هر دو را نگه دارد، نه فقط یکی را که به نفعش است.

این مقاله بار اثبات را هم مفید تنظیم می‌کند. اگر شرکتی می‌خواهد ادعا کند AI بالینی‌اش مراقبت را بهتر می‌کند، شاهد مرتبط leaderboard نیست؛ کارآزمایی‌ای مانند این است، روی پیامدهایی که برای بیمار مهم‌اند — و ترجیحاً بزرگ‌تر، چون درس صادقانهٔ این‌جا این است که برای دیدن منفعت متوسط به مطالعهٔ بزرگ نیاز دارید.

خلاصهٔ تمیز

یک کارآزمایی pragmatic و cluster-randomized در ۱۶ مرکز مراقبت اولیهٔ کنیا، ابزار پشتیبان تصمیم‌گیری AI مولد («AI Consult») را که به پروندهٔ الکترونیک clinical هایofficer افزوده شده بود آزمود. در میان ۹٬۶۹۱ بیمار، ترکیب داوری‌شدهٔ شکست درمان در ۱۴ روز، ۲٫۲٪ با ابزار در برابر ۲٫۰٪ بدون آن بود (adjusted OR 77.0، 95% CI 55.0–08.1، P = 13.0) — تفاوت معناداری وجود نداشت. ابزار هیچ سیگنال ایمنی نشان نداد، مستندسازی بالینی را در همهٔ حوزه‌های نمره‌گذاری‌شده بهتر کرد، نسخه‌نویسی را تغییر نداد، رضایت بیمار را ثابت گذاشت و با هزینهٔ اندکی کمتر آنتی‌بیوتیک همراه بود. نویسندگان نتیجه می‌گیرند در این محدودیت‌ها ایمن بود اما شکست درمان را کاهش نداد و هر منفعتی احتمالاً متوسط است؛ تشخیص اثری به اندازهٔ مشاهده‌شده به مطالعه‌ای بسیار بزرگ‌تر، در حد ۱۰۰٬۰۰۰ بیمار، نیاز دارد. نتیجه نشان نمی‌دهد AI بالینی پیامد بیمار را بهتر می‌کند و نشان هم نمی‌دهد بی‌فایده است — نشان می‌دهد ابزاری که ایمن به نظر رسید و فرایند را بهتر کرد، در یک شبکهٔ خصوصی شهری ظرف دو هفته منفعت قابل‌اثباتی برای بیمار ایجاد نکرد.

بررسی بی‌پرده

مقاله چه نشان می‌دهد: در یک کارآزمایی تصادفی واقعی، افزودن ابزار پشتیبان تصمیم مبتنی بر LLM به پروندهٔ مراقبت اولیه هیچ سیگنال ایمنی ایجاد نکرد، کیفیت مستندسازی را بهتر کرد، نسخه‌نویسی را تغییر نداد و ترکیب سخت‌گیرانهٔ شکست درمان ۱۴روزه را به‌طور معنادار کاهش نداد.

چه چیزی محتمل است اما اثبات نشده: ابزار کاهش کوچک واقعی در شکست درمان ایجاد می‌کند که این مطالعه برای دیدنش کوچک بوده؛ پس از حساب‌کردن همهٔ هزینه‌ها پول صرفه‌جویی می‌کند؛ یا مستندسازی بهتر در بلندمدت به مراقبت بهتر تبدیل می‌شود.

چه چیزی را نشان نمی‌دهد: AI بالینی پیامد بیماران را بهتر می‌کند؛ برای رویدادهای نادر ناایمن است؛ clinician را جایگزین می‌کند یا از او بهتر است؛ نتیجه به محیط روستایی یا پردرآمد منتقل می‌شود؛ یا صرفه‌جویی هزینه قطعی است.

محدودیت‌های اصلی: مطالعه برای اثر بزرگ‌تری از اثر مشاهده‌شده توان‌دهی شده بود؛ یک خطای پیکربندی بازوی کنترل را آلوده کرد و عادت‌های شبکهٔ مشترک نیز مقایسه را محو می‌کنند، هر دو به نفع «تفاوت صفر»؛ یک شبکهٔ خصوصی شهری با استاندارد نسبتاً بالا؛ نبود چارچوب ازپیش‌تعیین‌شدهٔ noninferiority یا ایمنی؛ افق کوتاه ۱۴روزه.

یک خوانندهٔ عمومی چقدر باید مطمئن باشد؟ اطمینان بالا که ابزار در این کارآزمایی سیگنال ایمنی نشان نداد و مستندسازی را بهتر کرد. اطمینان بالا که این‌جا منفعت قابل‌اثباتی برای پیامد ۱۴روزهٔ بیمار نشان نداد. اطمینان پایین به هر ادعای «کار می‌کند» یا «شکست خورده» به‌عنوان مداخلهٔ بیمارمحور — آن پرسش واقعاً باز است و مطالعهٔ بسیار بزرگ‌تری می‌خواهد. موضع مناسب: نتیجه‌ای دقیق و واقعی دربارهٔ ابزاری که ایمن به نظر رسید و فرایند مراقبت را بهتر کرد، نه حکم نهایی دربارهٔ این که AI مراقبت اولیه را متحول یا خراب می‌کند.

منابع

(2026) Medicine Nature al., et Agweyu
https://doi.org/10.1038/s41591-026-04503-6

202502499779176 registration Registry, Trials Clinical Pan-African
https://pactr.samrc.ac.za/

(2026) trial the on release press PATH / EurekAlert
https://www.eurekalert.org/news-releases/1133583