




The CLEAN PAPER

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

კლინიკური AI უსაფრთხოდ გამოიყურებოდა და დოკუმენტაციას აუმჯობესებდა — მაგრამ პაციენტების შედეგები არ გააუმჯობესა

კენიის პირველადი ჯანდაცვის 16 დაწესებულებაში ჩატარებულმა პრაქტიკულმა, კლასტერულად რანდომიზებულმა კვლევამ შეამოწმა გენერაციული AI-ის გადაწყვეტილების მხარდამჭერი ინსტრუმენტი, რომელიც კლინიკური ოფიცრების სამედიცინო ჩანაწერში იყო დამატებული. 9,691 პაციენტში ექსპერტების მიერ შეფასებული მკაცრი 14-დღიანი კომპოზიტური მკურნალობის წარუმატებლობა ინსტრუმენტით 2.2% იყო, მის გარეშე კი 2.0% (adjusted odds ratio 0.77, 95% CI 0.55–1.08, $P = 0.13$) — სტატისტიკურად მნიშვნელოვანი სხვაობა არ დაფიქსირდა. უსაფრთხოების სიგნალი არ გამოჩნდა, დოკუმენტაცია ყველა შეფასებულ სფეროში გაუმჯობესდა, დანიშნულებები და კმაყოფილება პრაქტიკულად უცვლელი დარჩა, ხოლო ანტიბიოტიკების ხარჯი შემცირების მიმართულებით წავიდა. ეს „ჩაგარდნილი“ კვლევა არ არის; იშვიათი გულწრფელი შედეგია, რომელიც პაციენტებზე და არა ბენიფიკატებზე გაზომეს: ინსტრუმენტმა პროცესი გააუმჯობესა და უსაფრთხოების პრობლემა არ აჩვენა, მაგრამ ორ კვირაში პაციენტისთვის სარგებელი ვერ დაადასტურა, ხოლო შესაძლო მცირე ეფექტის დასადგენად გაცილებით დიდი კვლევა იქნება საჭირო.

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: 10.1038/s41591-026-04503-6

უსაფრთხო და სასარგებლო იგივე არ არის, რაც ეფექტური

სამედიცინო AI-ზე ბევრი სათაური არასწორი ტიპის მტკიცებულებას ეყრდნობა. მოდელი გამოცდის კითხვებზე მაღალ ქულას იღებს ან საგულდაგულოდ შერჩეულ კლინიკურ სცენარებში ექიმებს სჯობნის და ამბავიც თითქოს მზადაა: მანქანა კლინიკისთვის მზად არის.

ეს კვლევა უფრო რთულ და ბევრად იშვიათ საქმეს აკეთებს. გენერაციულ AI-ზე დაფუძნებული გადაწყვეტილების მხარდამჭერი ინსტრუმენტი რეალურ პირველადი ჯანდაცვის დაწესებულებებში, რეალურ კლინიკისტებთან და რეალურ პაციენტებთან გამოიყენეს და დასვეს კითხვა, რომელსაც საბოლოოდ ყველაზე მეტი მნიშვნელობა აქვს: **პაციენტები უკეთ გახდნენ?**

პატიოსანი პასუხია — **არა, გაზომვადი გაუმჯობესება 14 დღეში არ გამოჩნდა.** ინსტრუმენტთან დაკავშირებული უსაფრთხოების სიგნალი არ გამოვლენილა. კლინიკური დოკუმენტაციის ხარისხი გაუმჯობესდა. შესაძლოა ზოგი მედიკამენტის ხარჯიც შემცირდა. მაგრამ მკურნალობის წარუმატებლობა მნიშვნელოვნად არ შემცირებულა და ავტორები ფრთხილად აღნიშნავენ, რომ სარგებელი, თუ საერთოდ არსებობს, ალბათ მცირეა.

ეს კვლევის წარუმატებლობა არ არის. პირიქით, ეს არის კვლევა, რომელიც სწორ კითხვას სვამს. სამედიცინო AI-ზე პასუხისმგებელიანი მტკიცებულება სწორედ ასე გამოიყურება, როცა შედეგს პაციენტებზე ზომავენ და არა მხოლოდ საორიენტაციო ტესტებზე.

Process improved; patient outcome not proven

Safe-looking decision support is not the same as a demonstrated clinical benefit.

No safety signal

Looked safe in this trial
Not powered to settle rare harms.




Workflow improved

Documentation quality rose
Process signal, not outcome proof.



Primary outcome null

14-day treatment failure
2.2% vs 2.0%; CI includes no effect.



Boundary: useful to the clinical process; not proven to improve patient outcomes within 14 days.

ინსტრუმენტთან დაკავშირებული უსაფრთხოების სიგნალი არ გამოვლენილა და კლინიკური დოკუმენტაცია გაუმჯობესდა, მაგრამ წინასწარ განსაზღვრული 14-დღიანი პაციენტური შედეგი მნიშვნელოვნად არ გაუმჯობესებულა. პროცესის დახმარება ჯერ კიდევ არ ნიშნავს პაციენტისთვის დადასტურებულ სარგებელს.

The Clean Paper CC BY 4.0

რა გააკეთეს ავტორებმა

გუნდმა პრაგმატული, კლასტერულად რანდომიზებული კვლევა ჩაატარა **16 პირველადი ჯანდაცვის დაწესებულებაში**, რომლებსაც ნაირობისა და კიამბუს ოლქებში კერძო ქსელი Penda Health მართავს. ამ დაწესებულებებში ზრუნვის დიდ ნაწილს **კლინიკური ოფიცრები** უზრუნველყოფენ — საშუალო რგოლის სპეციალისტები, რომლებსაც სამწლიანი დიპლომი აქვთ და ხშირად უფროს ექიმთან სწრაფი კონსულტაციის შესაძლებლობა არ აქვთ.

რანდომიზაციის ერთეული კლინიცისტი იყო და არა პაციენტი. **103 კლინიკური ოფიცერი** შემთხვევით გაანაწილეს: 52 ინტერვენციის ჯგუფში და 51 საკონტროლო ჯგუფში. ორივე ჯგუფი ერთსა და იმავე ღრუბლოვან ელექტრონულ სამედიცინო ჩანაწერს იყენებდა. ინტერვენციის ჯგუფს დამატებით ჰქონდა **AI Consult 2.0** — გადაწყვეტილების მხარდამჭერი ინსტრუმენტი, რომელიც **OpenAI GPT-4o** დიდ ენობრივ მოდელზე იყო აგებული და უშუალოდ ჩანაწერის სისტემაში მუშაობდა. იგი კლინიცისტის მიერ შეტანილ ინფორმაციას კითხულობდა და დიაგნოზის ან მკურნალობის გეგმის შესაძლო პრობლემებზე მიუთითებდა. საბოლოო გადაწყვეტილება მთლიანად კლინიცისტს რჩებოდა: რეკომენდაციის მიღება, შეცვლა ან უგულებელყოფა შეეძლო.

რომელი მოდელი გამოიყენეს და რატომ არის ეს დეტალი მნიშვნელოვანი

ინსტრუმენტი იყო **AI Consult 2.0**, რომელიც **OpenAI GPT-4o**-ზე მუშაობდა (2025 წლის მაისის ვერსია). სისტემა OpenAI-ის კომერციულ API-ს საწარმოო ლიცენზიით და დაბალი შემთხვევითობის პარამეტრით (temperature 0.1) იყენებდა. იგი EasyClinic-ის სპეციალურად შექმნილ ელექტრონულ სამედიცინო ჩანაწერში იყო ინტეგრირებული და სისტემური პრომპტებით კენიის ეროვნული მკურნალობის გაიდლაინებთან შესაბამისობაზე იყო მორგებული; ავტორები სრულ ინსტრუქციულ პრომპტსაც აქვეყნებენ.

რატომ არის ეს მნიშვნელოვანი? იმიტომ, რომ შედეგი ეხება **ერთ კონკრეტულ სისტემას** — მოდელის ერთ ვერსიას, ერთ პრომპტს, ერთ ჩანაწერის გარემოსა და ერთ პარამეტრულ კონფიგურაციას — და არა ზოგადად „მედიცინაში LLM-ებს“. ავტორებიც ამას ხაზს უსვამენ და შედეგს შესაძლებლობების ფიქსირებული შეფასების ნაცვლად დროის კონკრეტულ მომენტში მიღებულ საორიენტაციო ნიშნულად აღწერენ. უფრო ახალი მოდელი, სხვა პრომპტი ან ნაკლებად გაციფრულებული კლინიკა შეიძლება განსხვავებულ შედეგს

იდლეოდეს.

დამოუკიდებლობის მხრივ: OpenAI-მ მოგვიანებით კვლევას უსასყიდლო მხარდაჭერა მისცა — ღრუბლოვანი გამოთვლების კრედიტები და API-ის ტექნიკური კონსულტაცია — მაგრამ ავტორების თქმით, OpenAI-ის არჩევა მანამდე იყო გადაწყვეტილი და კომპანიას კვლევის დიზაინში, მონაცემთა შეგროვებაში, ანალიზში ან გამოქვეყნების გადაწყვეტილებაში მონაწილეობა არ ჰქონია.

2025 წლის 22 აპრილიდან 16 ივლისამდე კვლევაში **9,691 პაციენტი** ჩაერთო. **ძირითადი შედეგი შეგნებულად პაციენტზე ორიენტირებული და მკაცრი იყო:** ვიზიტიდან 14 დღეში ექსპერტების მიერ შეფასებული *მკურნალობის წარუმატებლობის კომპოზიტიური მაჩვენებელი*. კლინიცისტთა პანელმა, რომელმაც არ იცოდა პაციენტი რომელ ჯგუფში იყო, შეაფასა ჰქონდა თუ არა მას ცუდი შედეგი — მაგალითად გაურკვეველი ან გაუარესებული დაავადება. კვლევა წინასწარ იყო რეგისტრირებული (Pan-African Clinical Trials Registry 202502499779176).

სწორედ ეს დიზაინი არის მთავარი. მარტივია აჩვენო, რომ AI ინსტრუმენტი კლინიცისტის ჩანაწერებს ცვლის. ბევრად რთული და მნიშვნელოვანი საკითხია, ცვლის თუ არა ის პაციენტის ჯანმრთელობის შედეგს.

რა აღმოაჩინეს

ძირითადი შედეგი არ გაუმჯობესდა. მკურნალობის წარუმატებლობა AI-ის ჯგუფში 4,693 პაციენტიდან 102-ს (2.2%), ხოლო საკონტროლო ჯგუფში 4,654-დან 94-ს (2.0%) ჰქონდა. დაუმუშავებელი პროცენტები AI-ის ჯგუფში ოდნავ უფრო მაღალი იყო, მაგრამ კორექციის შემდეგ წერტილოვანი შეფასება სარგებლის მიმართულებით გადავიდა: **შესწორებული შანსების თანაფარდობა 0.77 (95% CI 0.55-1.08, P = 0.13)** — სტატისტიკურად მნიშვნელოვანი შედეგი არ იყო. დაუმუშავებელი და შესწორებული რიცხვების მიმართულების განსხვავება არითმეტიკული შეცდომა არ არის; კორექცია კლინიცისტთა კლასტერებს შორის განსხვავებებს ითვალისწინებს. ორივე შემთხვევაში სანდოობის ინტერვალი თავისუფლად მოიცავს „ეფექტის არარსებობას“, ამიტომ სარგებლის მტკიცება შეუძლებელია, ხოლო აბსოლუტური განსხვავება ძალიან მცირე იყო.

შანსების თანაფარდობის, სანდოობის ინტერვალისა და P-მნიშვნელობის ერთობლივად წაკითხვისთვის იხილეთ კლინიკური შედეგების გზამკვლევი.

უსაფრთხოების სიგნალი არ გამოჩნდა — თუმცა ამას საზღვრები აქვს. ინსტრუმენტთან დაკავშირებული სერიოზული არასასურველი მოვლენა არ დაფიქსირებულა და დამოუკიდებელმა მიმოხილვამ უსაფრთხოების სიგნალი ვერ აღმოაჩინა. ავტორები ამ დამამშვიდებელი შედეგის ზღვარსაც პირდაპირ აღწერენ: კვლევა იშვიათი მძიმე ზიანის გამოსავლენად საკმარისი სიმძლავრით დაგეგმილი არ ყოფილა და წინასწარ განსაზღვრული noninferiority ან ფორმალური უსაფრთხოების ჩარჩო არ ჰქონდა.

ამიტომ იშვიათ მოვლენებთან მიმართებით უსაფრთხოებას ვერ ამტკიცებს.

დოკუმენტაცია უკეთესი გახდა. დაბრმავებული ექსპერტების მიერ შეფასებულ 2,000 ვიზიტში AI Consult-ის მომხმარებლებს კლინიკური დოკუმენტაცია ყველა შეფასებულ სფეროში უკეთესი ჰქონდათ — დიაგნოზის ჩაწერა, მკურნალობის გეგმა და საერთო სრულყოფილება.

მედიკამენტების დანიშვნა თითქმის არ შეცვლილა. მნიშვნელოვანი განსხვავება დანიშნულ მედიკამენტებში, მათ შორის ანტიბიოტიკების სწორ გამოყენებაში, არ აღმოჩნდა (შესწორებული შანსების თანაფარდობა 0.86, 95% CI 0.48–1.55). ინსტრუმენტს ანტიბიოტიკების დანიშვნის სიხშირე არ შეუცვლია.

პაციენტები განსხვავებას ვერ გრძნობდნენ. კმაყოფილების გამოკითხვის 826 მონაწილეში ჯგუფებს შორის კმაყოფილება პრაქტიკულად ერთნაირი იყო; კონსულტაციის ხანგრძლივობაც მსგავსი დარჩა.

ხარჯები მცირედ შემცირების მიმართულებით მიუთითებდა. შესწორებულ ანალიზში ანტიბიოტიკებთან დაკავშირებული ხარჯები AI-ის ჯგუფში უფრო დაბალი იყო — სავარაუდოდ უფრო იაფი არჩევანის და არა ნაკლები დანიშნულების გამო — ხოლო ერთ პაციენტზე ანტიბიოტიკებზე დაზოგილი თანხა ინსტრუმენტის ერთ პაციენტზე საოპერაციო ხარჯს აღემატებოდა. ავტორები ამას მხოლოდ საყურადღებო სიგნალად აღწერენ და არა დადასტურებულ შედეგად: საკუთრების სრული ღირებულების ეკონომიკური ანალიზი კვლევის ფარგლებს არ მოიცავდა.

ავტორების ერთწინადადებიანი შეჯამება ყველაზე ზუსტია: ამ პირობებში LLM-ის დახმარება უსაფრთხოდ გამოიყურებოდა, მაგრამ 14-დღიანი მკურნალობის წარუმატებლობა არ შეამცირა; თუ სარგებელი არსებობს, ის ალბათ მცირეა.

რატომ არ ნიშნავს „სტატისტიკურად მნიშვნელოვან განსხვავება არ ყოფილა“ იმას, რომ „არ მუშაობს“

ნულოვანი ძირითადი შედეგი ორივე მიმართულებით ადვილად შეიძლება გადაჭარბებულად წავიკითხოთ. ორ ფაქტორს ეს მარტივი ამბავი ართულებს.

პირველი: კვლევა უფრო დიდი ეფექტის გამოსავლენად იყო დაგეგმილი, ვიდრე რეალურად დაფიქსირდა. პირველადი ჯანდაცვის პირობებში სერიოზული ცუდი შედეგები იშვიათი იყო — აქ დაახლოებით 2% — ამიტომ მცირე რეალური სარგებლის სტატისტიკური ხმაურისგან გასარჩევად უზარმაზარი ნიმუშია საჭირო. ავტორების შემდგომი სიმძლავრის გამოთვლები მიუთითებს, რომ დაფიქსირებული ზომის ეფექტის გამოსავლენად **100,000-ზე მეტი პაციენტის მქონე ბევრად უფრო დიდი კვლევა** იქნებოდა საჭირო. ამ ზომის კვლევაში სტატისტიკურად არამნიშვნელოვანი შედეგი მცირე რეალურ სარგებელს არ გამორიცხავს; იგი მხოლოდ ნიშნავს, რომ ამ კვლევას მისი საიმედოდ გარჩევა არ შეეძლო.

მეორე: **შედარება ნაწილობრივ დაბინდული იყო.** კონფიდურაციის შეცდომამ საკონტროლო ჯგუფის რამდენიმე კლინიცისტს დროებით AI Consult-ზე წვდომა მისცა; ერთსა და იმავე ქსელში კლინიცისტები ერთმანეთთან ურთიერთობენ და სამუშაო ჩვევებიც ჯგუფებს შორის შეიძლება გავრცელდეს. ორივე ფაქტორი ჯგუფებს ერთმანეთის მსგავსს ხდის და ნამდვილ განსხვავებას ნულისკენ მიკერძოებულად ამცირებს. გარდა ამისა, ქსელი უკვე შედარებით მაღალი სტანდარტით მუშაობდა, ამიტომ გაუმჯობესებისთვის სივრცე ნაკლები იყო.

ეს შეზღუდვები „გარღვევის“ სათაურს არ ამართლებს. სწორი წაკითხვა უფრო ზომიერია: ყველაზე მკაცრ და პაციენტისთვის ყველაზე მნიშვნელოვან საბოლოო მაჩვენებელზე ინსტრუმენტმა ორ კვირაში აშკარა სარგებელი ვერ აჩვენა — ამავე დროს დოკუმენტაცია გაზომვადად გააუმჯობესა და უსაფრთხოდ გამოიყურებოდა.

რას არ ამტკიცებს ეს

- ეს არ აჩვენებს, რომ AI-მა პაციენტების შედეგები გააუმჯობესა. ძირითად 14-დღიან საბოლოო მაჩვენებელზე მნიშვნელოვანი სარგებელი არ დაფიქსირებულა.
- ეს არ აჩვენებს, რომ AI უსარგებლოა. წერტილოვანი შეფასება სარგებლის მიმართულებით იყო, დოკუმენტაცია ყველა შეფასებულ სფეროში გაუმჯობესდა და მედიკამენტების ხარჯებიც შემცირებისკენ მიუთითებდა; ნულოვანი შედეგი თავსებადია მცირე რეალურ სარგებელთან, რომლის დასადასტურებლად ეს კვლევა ძალიან მცირე იყო.
- ეს არ ამტკიცებს უსაფრთხოებას იშვიათი ზიანის მიმართ. უსაფრთხოების სიგნალი არ გამოჩნდა, მაგრამ კვლევა იშვიათი მძიმე მოვლენების გამოსავლენად ან უსაფრთხოების დასადასტურებლად არ ყოფილა შექმნილი.
- ეს არ აჩვენებს, რომ „AI ექიმებს სჯობნის“ ან კლინიცისტებს ცვლის. ეს იყო გადაწყვეტილების მხარდაჭერა; რეკომენდაციის მიღების, უარყოფის ან შეცვლის უფლება მთლიანად კლინიცისტს რჩებოდა.
- შედეგი ავტომატურად არ განზოგადდება. კვლევა ერთ კერძო, ურბანულ კენიურ ქსელში ჩატარდა; სოფლის, პერიურბანული ან მაღალშემოსავლიანი გარემო განსხვავებულ შედეგს შეიძლება იძლეოდეს.
- ეს არ ამტკიცებს ხარჯების დაზოგვას. ეკონომიკური სიგნალი საყურადღებოა, მაგრამ სრული ეკონომიკური შეფასება არ ჩატარებულა.

რამდენად ძლიერია მტკიცებულება?

ცენტრალური მტკიცებისთვის — მოკლევადიანი პაციენტური ზიანის დადასტურებული შემცირება არ გვაქვს — მტკიცებულება დიზაინის მხრივ ძლიერია და დასკვნა სათანადოდ ფრთხილი. პროსპექტული, წინასწარ რეგისტრირებული, კლასტერულად რანდომიზებული კვლევა დაბრმავებული, პაციენტის დონის კომპოზიტური შედეგით ახლოსაა საუკეთესო რეალურ პირობებში მიღებულ მტკიცებულებასთან, რაც ასეთი

ინსტრუმენტისთვის შეიძლება მოვიპოვოთ. ეს ბევრად უფრო ინფორმაციულია, ვიდრე საორიენტაციო ტესტის ქულა ან კლინიკურ სცენარებზე დაფუძნებული კვლევა.

მეორეული მიგნებები — უკეთესი დოკუმენტაცია, უცვლელი მედიკამენტების დანიშვნა, მსგავსი კმაყოფილება და შედარებით დაბალი ანტიბიოტიკების ხარჯები — სასარგებლო მტკიცებულებაა, მაგრამ მეორეულად უნდა წავიკითხოთ: ისინი დამხმარე სიგნალებია და არა მთავარი სათაური, თანაც იგივე დაბინძურებისა და ერთი ქსელის შეზღუდვები ახლავს.

უსაფრთხოების მტკიცებულება დამამშვიდებელია, მაგრამ შეზღუდული: სიგნალი ვერ აღმოაჩინეს, თუმცა კვლევა იშვიათი ზიანის გამოსავლენად არ ყოფილა შექმნილი.

ყველაზე სასარგებლო პოზიცია არც „მუშაობს“ არის და არც „ჩავარდა“. უფრო ზუსტად: რეალურ პირობებში ჩატარებულ ფრთხილ კვლევაში AI ინსტრუმენტს უსაფრთხოების სიგნალი არ გამოუვლენია და ზრუნვის პროცესის ნაწილი გააუმჯობესა, მაგრამ ორ კვირაში პაციენტის შედეგზე აშკარა სარგებელი ვერ აჩვენა — ხოლო ასეთი მცირე სარგებლის გამოვლენა ბევრად უფრო დიდ კვლევას მოითხოვდა.

რატომ არის მნიშვნელოვანი

სამედიცინო AI-ზე დებატს ზუსტად ასეთი მტკიცებულება აკლია. ათასობით ნაშრომი აჩვენებს მოდელის წარმატებას გამოცდებზე ან საგულდაგულოდ შერჩეულ შემთხვევებში ექიმებთან შედარებით. ბევრად ნაკლებია დიდი, პრაგმატული, რანდომიზებული კვლევა, რომელიც კითხულობს, რეალური პაციენტები უკეთ არიან თუ არა. ეს ერთ-ერთი ასეთი კვლევაა და საკმაოდ არაგლამურულ ჭეშმარიტებამდე მიდის: **ტესტის ჩაბარება პაციენტის დახმარებას არ ნიშნავს.**

სწორედ ეს განსხვავებაა მთელი ამბავი. ინსტრუმენტი შეიძლება კლინიცისტებისთვის ნამდვილად სასარგებლო იყოს — უკეთესი ჩანაწერები, უფრო დაბალი მედიკამენტების ხარჯი, დამატებითი „მეორე თვალები“ — და მაინც ვერ შეცვალავს მკაცრი პაციენტური შედეგი ორ კვირაში. ორივე ფაქტი ერთდროულად შეიძლება იყოს მართალი და მოწიფულმა ჯანდაცვის სისტემამ ორივე უნდა გაითვალისწინოს.

ეს მტკიცების ტვირთსაც სასარგებლო მიმართულებით აბრუნებს. თუ კომპანია ამბობს, რომ კლინიკური AI ზრუნვას აუმჯობესებს, მთავარი მტკიცებულება ლიდერბორდი არ არის. საჭიროა მსგავსი კვლევა პაციენტისთვის მნიშვნელოვან შედეგებზე — სასურველია უფრო დიდი, რადგან ამ კვლევის პატიოსანი გაკვეთილი ისიცაა, რომ მცირე სარგებლის დასანახად დიდი კვლევებია საჭირო.

მოკლე შეჯამება

კენიის 16 პირველადი ჯანდაცვის დაწესებულებაში ჩატარებულ პრაგმატულ, კლასტერულად რანდომიზებულ კვლევაში გამოსცადეს გენერაციულ AI-ზე დაფუძნებული გადაწყვეტილების მხარდამჭერი ინსტრუმენტი **AI Consult**, რომელიც კლინიკური ოფიცრების ელექტრონულ სამედიცინო ჩანაწერში იყო ინტეგრირებული. **9,691 პაციენტში** ექსპერტების მიერ შეფასებული 14-დღიანი კომპოზიტური მკურნალობის წარუმატებლობა ინსტრუმენტით 2.2% და მის გარეშე 2.0% იყო (შესწორებული შანსების თანაფარდობა 0.77, 95% CI 0.55–1.08, $P = 0.13$) — **სტატისტიკურად მნიშვნელოვანი განსხვავება არ ყოფილა**. ინსტრუმენტთან დაკავშირებული უსაფრთხოების სიგნალი არ გამოვლენილა, დოკუმენტაცია ყველა შეფასებულ სფეროში გაუმჯობესდა, მედიკამენტების დანიშვნა და პაციენტთა კმაყოფილება პრაქტიკულად არ შეცვლილა, ხოლო ანტიბიოტიკებთან დაკავშირებული ხარჯები მცირედ შემცირებისკენ მიუთითებდა. ავტორები ასკვნიან, რომ ამ პირობებში სისტემა უსაფრთხოდ გამოიყურებოდა, მაგრამ მკურნალობის წარუმატებლობა არ შეამცირა და შესაძლო სარგებელი ალბათ მცირეა; დაფიქსირებული ზომის ეფექტის საიმედოდ გამოსავლენად დაახლოებით 100,000-ზე მეტი პაციენტის მქონე კვლევა იქნებოდა საჭირო. შედეგი არც იმას ამტკიცებს, რომ კლინიკური AI პაციენტის შედეგებს აუმჯობესებს, და არც იმას, რომ ის უსარგებლოა — იგი აჩვენებს ინსტრუმენტს, რომელმაც პროცესი გააუმჯობესა, მაგრამ ერთ ურბანულ კერძო ქსელში ორ კვირაში პაციენტის ამკარა სარგებელი ვერ აჩვენა.

ზედმეტი ხმაურის გარეშე

რას აჩვენებს ნაშრომი: რეალურ პირობებში ჩატარებულ რანდომიზებულ კვლევაში პირველადი ჯანდაცვის ჩანაწერებში LLM-ზე დაფუძნებული გადაწყვეტილების მხარდამჭერი ინსტრუმენტის დამატებას უსაფრთხოების სიგნალი არ მოჰყოლია, კლინიკური დოკუმენტაციის ხარისხი გაუმჯობესდა, მედიკამენტების დანიშვნა არსებითად არ შეცვლილა და მკაცრი 14-დღიანი პაციენტური კომპოზიტური მკურნალობის წარუმატებლობა მნიშვნელოვნად არ შემცირებულა.

რა არის სარწმუნო, მაგრამ დაუმტკიცებელი: რომ ინსტრუმენტი მკურნალობის წარუმატებლობას მცირედ ამცირებს, მაგრამ კვლევა ამის გამოსავლენად საკმარისად დიდი არ იყო; რომ ყველა ხარჯის გათვალისწინებით ის ფულს ზოგავს; ან რომ უკეთესი დოკუმენტაცია საბოლოოდ უკეთეს ზრუნვად გარდაიქმნება.

რას არ აჩვენებს: რომ კლინიკური AI პაციენტურ შედეგებს აუმჯობესებს; რომ იშვიათ მოვლენებთან მიმართებით უსაფრთხოება დადასტურებულია; რომ ინსტრუმენტი კლინიცისტებს ცვლის ან სჯობნის; რომ შედეგი ავტომატურად გადაიტანება სოფლის ან მაღალშემოსავლიან გარემოზე; ან რომ ხარჯების დაზოგვა დადასტურებულია.

მთავარი შეზღუდვები: კვლევა უფრო დიდი ეფექტის გამოსავლენად იყო დაგეგმილი, ვიდრე დაფიქსირდა, ხოლო იშვიათი შედეგები უზარმაზარ ნიმუშს მოითხოვს; კონფიგურაციის

შეცდომამ საკონტროლო ჯგუფი ნაწილობრივ „დააბინძურა“ და საერთო ქსელში სამუშაო ჩვევების გავრცელებამ ჯგუფებს შორის განსხვავება შეიძლება შეამცირა; კვლევა ჩატარდა ერთ კერძო ურბანულ ქსელში, რომელსაც უკვე მაღალი საწყისი სტანდარტები ჰქონდა; წინასწარ განსაზღვრული noninferiority ან ფორმალური უსაფრთხოების ჩარჩო არ ყოფილა; დაკვირვების პერიზონტი მხოლოდ 14 დღე იყო.

რამდენად უნდა ენდოს ამას ზოგადი მკითხველი? მაღალი ნდობა იმისა, რომ ამ კვლევაში ინსტრუმენტთან დაკავშირებული უსაფრთხოების სიგნალი არ გამოჩნდა და დოკუმენტაცია გაუმჯობესდა. მაღალი ნდობა იმისა, რომ 14-დღიან პაციენტურ შედეგზე აშკარა გაუმჯობესება არ დაფიქსირებულა. დაბალი ნდობა ნებისმიერ საბოლოო განაჩენზე — „მუშაობს“ ან „არ მუშაობს“ — რადგან პაციენტური სარგებელი როგორც ინტერვენციის საბოლოო ეფექტი ჯერ ნამდვილად გაურკვეველია და ბევრად უფრო დიდ კვლევას საჭიროებს. სათანადო პოზიციაა: ფრთხილი რეალურ პირობებში მიღებული შედეგი ინსტრუმენტზე, რომელმაც პროცესი გააუმჯობესა — და არა განაჩენი, რომ AI პირველადი ჯანდაცვას ან გარდაქმნის, ან ანადგურებს.

წყაროები

Agweyu et al., Nature Medicine (2026)

<https://doi.org/10.1038/s41591-026-04503-6>

Pan-African Clinical Trials Registry, registration 202502499779176

<https://pactr.samrc.ac.za/>

EurekaAlert / PATH press release on the trial (2026)

<https://www.eurekaalert.org/news-releases/1133583>