Revista Eletrônica
Acervo Saúde
Electronic Journal Collection Health ISSN 2178-2091

Inteligência artificial na atenção primária à saúde

Artificial intelligence in primary health care

Inteligencia artificial en la atención primaria de salud

João Geraldo de Oliveira Júnior[1], Marcel de Moraes Pedroso[1].

RESUMO

Objetivo: Analisar as aplicações, percepções de usuários, barreiras de implementação e implicações éticas da Inteligência Artificial (IA) na Atenção Primária à Saúde (APS), propondo estratégias para sua integração segura e equânime. **Métodos:** Revisão integrativa com coleta de dados em bases científicas (2020-2025). O objeto compreende a produção global sobre IA na APS, utilizando protocolo estruturado com descritores controlados (MeSH/DeCS) e critérios de inclusão focados na temática. **Resultados:** Os resultados revelam um paradoxo de maturidade: enquanto oftalmologia e dermatologia atingem precisão técnica avançada, a integração assistencial permanece fragmentada por uma "especialização contextual". O Norte Global automatiza a eficiência administrativa, enquanto o Sul Global utiliza a IA como equalizador de acesso via *leapfrogging* tecnológico. Identificou-se um "otimismo cauteloso": profissionais enfrentam o dilema do *deskilling* e da desumanização do vínculo, ao passo que pacientes priorizam a celeridade diagnóstica. Interoperabilidade, dados de qualidade e governança emergem como gargalos críticos que impedem a transição definitiva da validação *in silico* para o mundo real. **Considerações finais:** O ponto forte deste estudo é a síntese multidimensional inédita que integra evidências técnicas às dimensões socioculturais e éticas específicas da APS. A principal limitação reside na exclusão de inovações proprietárias protegidas por *paywalls* institucionais.

Palavras-chave: Atenção primária à saúde, Inteligência artificial, Sistemas inteligentes.

ABSTRACT

Objective: To analyze applications, user perceptions, implementation barriers, and ethical implications of Artificial Intelligence (AI) in Primary Health Care (PHC), proposing strategies for safe and equitable integration. **Methods:** Integrative review with data collection from scientific databases (2020-2025). The study object comprises global scientific production on AI in PHC, utilizing a structured protocol with controlled descriptors (MeSH/DeCS) and thematic inclusion criteria. **Results:** Results reveal a maturity paradox: while fields such as ophthalmology and dermatology achieve advanced technical precision, clinical integration remains fragmented by "contextual specialization." The Global North focuses on administrative efficiency, whereas the Global South employs AI as an access equalizer via technological leapfrogging. A "cautious optimism" was identified: professionals face the dilemma of deskilling and the dehumanization of the therapeutic bond, while patients prioritize diagnostic speed. Interoperability, data quality, and governance emerge as critical

[1] Instituto de Comunicação e Informação Científica e Tecnológica em Saúde/ Fiocruz (ICICT/FIOCRUZ), Rio de Janeiro – RJ.

SUBMETIDO EM: 3/2026 | **ACEITO EM: 4/2026** | **PUBLICADO EM: 5/2026**

bottlenecks hindering the definitive transition from *in silico* validation to real-world application. **Final considerations:** The study's strength is its unique multidimensional synthesis, integrating technical evidence with PHC-specific sociocultural and ethical dimensions. The limitation lies in the exclusion of proprietary innovations under institutional paywalls.

Keywords: Primary health care, Artificial intelligence, Intelligent systems.

RESUMEN

Objetivo: Analizar aplicaciones, percepciones de usuarios, barreras e implicaciones éticas de la Inteligencia Artificial (IA) en la Atención Primaria de Salud (APS), proponiendo estrategias de integración segura y equitativa. **Métodos:** Revisión integradora con recolección de datos en bases científicas (2020-2025). El objeto comprende la producción global sobre IA en APS, utilizando protocolo estructurado con descriptores controlados (MeSH/DeCS) y criterios de inclusión temáticos. **Resultados:** Los resultados revelan una paradoja de madurez: mientras oftalmología y dermatología alcanzan precisión técnica avanzada, la integración asistencial sigue fragmentada por una "especialización contextual". El Norte Global automatiza la eficiencia administrativa, mientras el Sur Global usa la IA como ecualizador de acceso vía *leapfrogging* tecnológico. Se identificó un "optimismo cauteloso": profesionales enfrentan el dilema del *deskilling* y la deshumanización del vínculo, mientras pacientes priorizar la celeridad diagnóstica. Interoperabilidad, calidad de datos y gobernanza emergen como cuellos de botella críticos que impiden la transición definitiva de la validación *in silico* al mundo real. **Consideraciones finales:** El punto fuerte es la síntesis multidimensional inédita que integra evidencias técnicas con dimensiones socioculturales y éticas de la APS. La limitación reside en la exclusión de innovaciones bajo *paywalls*.

Palabras clave: Atención primaria de salud, Inteligencia artificial, Sistemas inteligentes

INTRODUÇÃO

A Atenção Primária à Saúde (APS) é a porta de entrada estratégica dos sistemas de saúde. Diante do envelhecimento populacional e da sobrecarga dos serviços, a Inteligência Artificial (IA) surge como uma tecnologia promissora para ampliar a resolutividade e a personalização do cuidado, esta é definida como um conjunto de métodos computacionais para tarefas cognitivas como o raciocínio clínico (YOUNG RA, et al., 2024).

Embora o processamento de grandes volumes de dados de registros eletrônicos permita cruzamentos complexos via redes neurais e outras técnicas, a prática clínica envolve dimensões humanas que extrapolam algoritmos. O problema central reside na desconexão entre a maturidade técnica da IA e os desafios operacionais da APS. Surgem, assim, preocupações éticas, necessidade de literacia digital para mitigar a “tendência à automação” (BRESSAN T, et al., 2025) e resistências culturais quanto à autonomia decisória (TERRY AL, et al., 2022). Além disso, a aplicação em larga escala enfrenta o risco de agravar disparidades preexistentes se não houver ajustes voltados à equidade e à infraestrutura local.

Dessa forma, apesar da expansão global da IA no apoio à decisão e fluxos de trabalho, persistem limitações técnicas e desafios de equidade que exigem monitoramento contínuo. O panorama atual é híbrido: se por um lado há ganhos em eficiência, por outro permanecem incertezas sobre a qualidade relacional e a justiça distributiva nos serviços públicos.

Este artigo apresenta uma contribuição inédita ao oferecer uma síntese multidimensional que integra evidências técnicas às dimensões socioculturais e éticas da APS. Ao preencher a lacuna entre a teoria computacional e a viabilidade operacional, fornece um framework crítico para a incorporação segura e equânime dessas tecnologias no Sistema Único de Saúde (SUS).

O objetivo é explorar as áreas de adoção da IA, as percepções de usuários e profissionais, as barreiras à implementação e as implicações éticas e socioculturais envolvidas, orientando gestores na tomada de decisão estratégica para a incorporação da IA em larga escala.

MÉTODOS

Esta revisão integrativa fundamenta-se na capacidade de sintetizar evidências experimentais, não experimentais, teóricas e empíricas para uma compreensão profunda do fenômeno investigado (SOUZA MT, et al., 2010).

A seleção dos estudos foi guiada por cinco perguntas orientadoras: Quais domínios da APS têm sido objeto de intervenções de IA e quais emergem como prioridades científicas? Como a literatura aborda as percepções de profissionais e pacientes sobre o uso dessa tecnologia? Quais barreiras técnicas e operacionais precisam ser superadas para sua adoção efetiva? Quais são as principais implicações éticas e socioculturais identificadas? Quais estratégias são propostas para a implementação da IA em larga escala na APS?

A busca utilizou os descritores estruturados (DeCS/MeSH) “inteligência artificial” AND “atenção primária à saúde” nas bases Web of Science, LILACS, Scopus e PubMed. Os critérios de inclusão contemplaram artigos em português, inglês ou espanhol, publicados entre 2020 e 2025 disponíveis na íntegra sem custos. A opção pelo acesso aberto visou a reprodutibilidade em contextos de recursos limitados, embora se reconheça o potencial viés de seleção. Tal limitação é ponderada pela robustez da amostra final (n=274), que permitiu saturação teórica sobre o estado da arte.

A triagem foi operacionalizada na plataforma Rayyan®, envolvendo a remoção de duplicatas e a análise criteriosa de títulos, resumos e textos na íntegra. Para a interpretação dos resultados, aplicou-se a análise temática (BRAUN V e CLARKE V, 2013), processo que exigiu interpretação subjetiva dos autores na codificação e organização de variáveis categóricas. Para mitigar enviesamentos, as categorias foram validadas por todos os autores, assegurando a consistência das inferências.

O percurso analítico envolveu: 1) imersão e anotações; 2) criação de códigos a partir da identificação de palavras ou parágrafos relacionados a tópicos específicos; 3) agrupamento em variáveis categóricas para identificação de padrões e divergências; e 4) construção dos temas centrais (**Quadro 1**). Preceitos éticos de autoria e citação foram rigorosamente observados.

Quadro 1 - Processo de agrupamento das variáveis categóricas em temas.

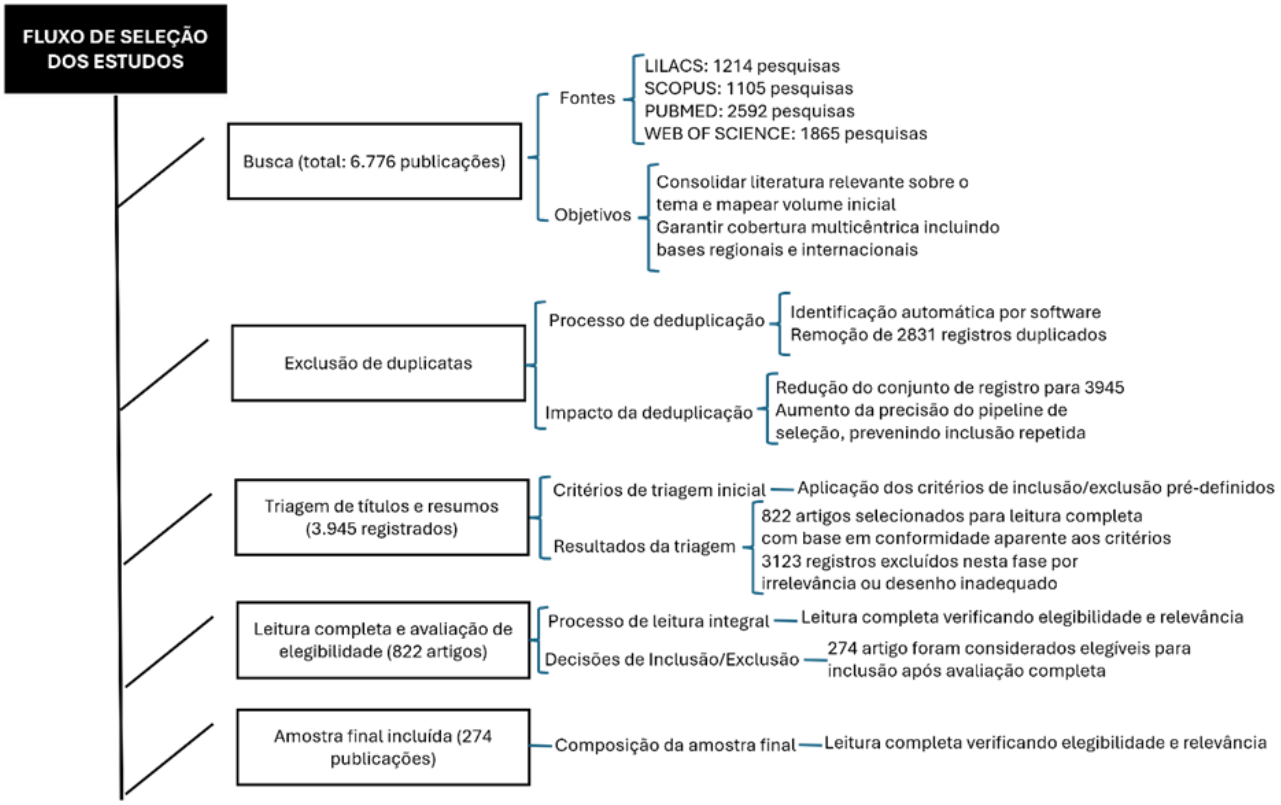
Códigos	Variáveis Categóricas	Temas Amplos	Descrição
Triagem, diagnóstico, monitoramento, gestão administrativa, acesso, longitudinalidade, promoção, prevenção ...	Modos de uso da IA.	Áreas de aplicação da IA na APS.	Funções assumidas pela IA e os atributos da APS que essa tecnologia tem impulsionado.
Privacidade, consentimento, viés, Impacto no vínculo, iniquidades ...	Ética e Aspectos socioculturais.	Aspectos éticos e socioculturais a considerar.	Preocupações éticas/ socioculturais dos envolvidos com a IA.
Confiança, aceitação, resistência ...	Percepções dos usuários da IA.	Percepções dos profissionais e pacientes na utilização da IA.	Percepções sobre o uso da IA na APS.
Infraestrutura, financiamento, governança, regulamentação, auditorias, competências digitais, formação ...	Necessidades para Implementação da IA na APS.	Condições e necessidades para implementação efetiva.	Condições estruturais, organizacionais e humanas para a implementação da IA.
Avaliação, piloto, escalonamento, métricas claras, modelos híbridos, adaptar à realidade ...	Ações para implementação da IA na APS	Caminhos e estratégias para ampla adoção da IA na APS	Formas viáveis e direcionamentos para a implementação da IA em larga escala na APS

Fonte: Oliveira Junior JG e Pedroso MM, 2026.

RESULTADOS

As buscas iniciais retornaram 6.776 publicações. Após a exclusão de 2.831 duplicatas, 3.945 registros foram submetidos à leitura de títulos e resumos. Desse total, 822 artigos foram selecionados para análise integral, resultando em uma amostra final de 274 estudos que atenderam aos critérios de inclusão (**Figura 1**).

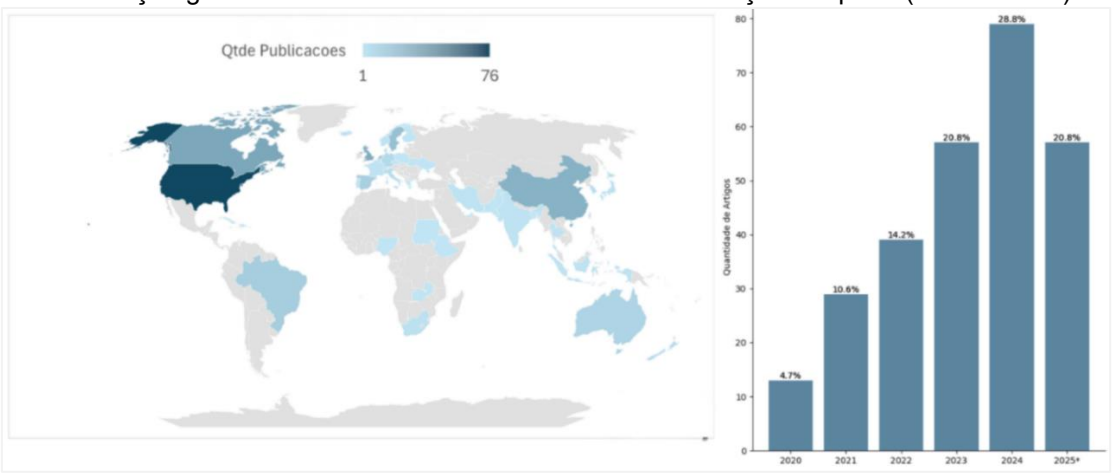
Figura 1 - Etapas da seleção dos estudos que compuseram a pesquisa.



Fonte: Oliveira Junior JG e Pedroso MM, 2026.

Os dados revelam um campo em rápida maturação, com incremento acelerado de publicações entre 2023 e 2025. Enquanto o período 2020–2022 apresentou produção limitada e concentrada nos Estados Unidos. Os anos recentes destacam-se pela maior produtividade e diversidade geográfica dos países proponentes. Quanto à distribuição geográfica, os Estados Unidos lideram a produção (n=76), seguidos por Canadá (n=30), Reino Unido (n=28), China (n=25), Suécia (n=18) e Brasil (n=12). A Europa apresenta capilaridade relevante, com contribuições de nações como Alemanha, Espanha, Holanda e Portugal, entre outras. Observa-se ainda uma inserção crescente de países em desenvolvimento da África, Ásia e América Latina (ex: Nigéria, Índia, Cuba e Paquistão), além de colaborações multilaterais envolvendo o Oriente Médio e a Oceania (**Figura 2**).

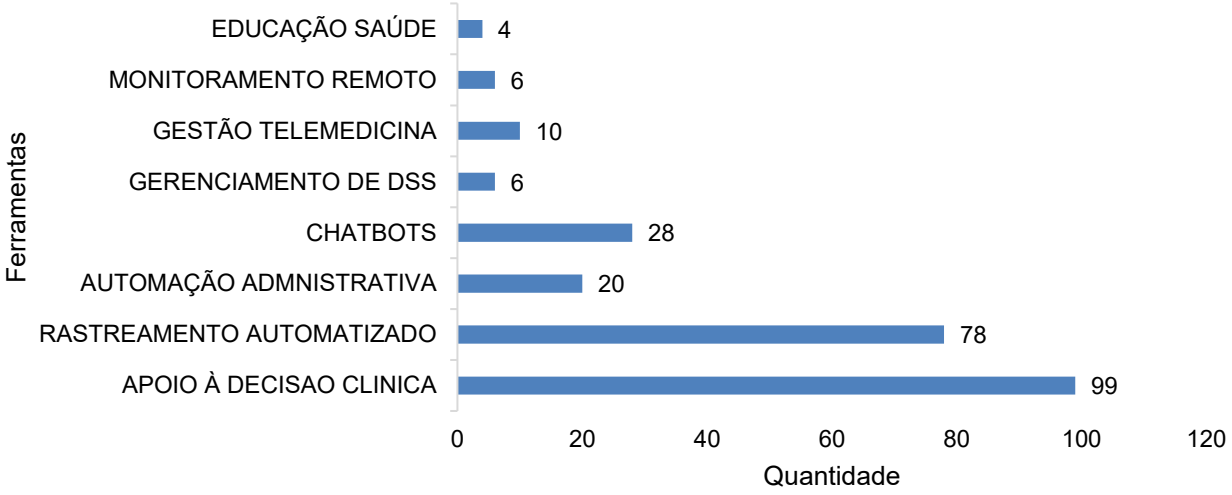
Figura 2 - Distribuição global de estudos sobre IA na APS e sua evolução temporal (2020 a 2025).



Nota: * até novembro de 2025. **Fonte:** Oliveira Junior JG e Pedroso MM, 2026.

A **Figura 2** ainda demonstra a centralidade do Norte Global, mas aponta para uma internacionalização do debate sobre a IA no contexto da Atenção Primária, com a emergência do Sul Global. A análise apontou para a predominância de ferramentas de apoio à decisão clínica, evidenciando que a principal aplicação da IA na APS tem sido voltada ao suporte direto ao processo da conduta clínica e terapêutica. Seguem-se os sistemas de rastreamento automatizado de patologias e diagnóstico precoce, reforçando o caráter preventivo e de ampliação do acesso da IA na APS. Também foram expressivas as tecnologias para automação administrativa e *chatbots*, voltadas à otimização de fluxos e comunicação com pacientes. Em menor escala, surgem áreas emergentes como o gerenciamento de determinantes sociais de saúde (DSS), gestão em telemedicina, monitoramento remoto e educação em saúde. Embora menos frequentes, estas modalidades indicam um potencial para fortalecer a longitudinalidade e a equidade do cuidado em contextos de vulnerabilidade (**Gráfico 1**).

Gráfico 1 - A frequência em números absolutos de sistemas que foram avaliados nas pesquisas.



Fonte: Oliveira Junior JG e Pedroso MM, 2026.

No geral, as aplicações de IA concentram-se em funções clínicas e de triagem, mas expandem-se para dimensões administrativas, comunicacionais e educativas. Esse cenário híbrido reflete uma inovação voltada tanto ao cuidado direto quanto ao suporte organizacional, integrando a tecnologia à rotina dos serviços de saúde (**Quadro 2**).

Quadro 2 - Área de aplicação, IA associada, fundamento tecnológico e evidências científicas da IA na APS

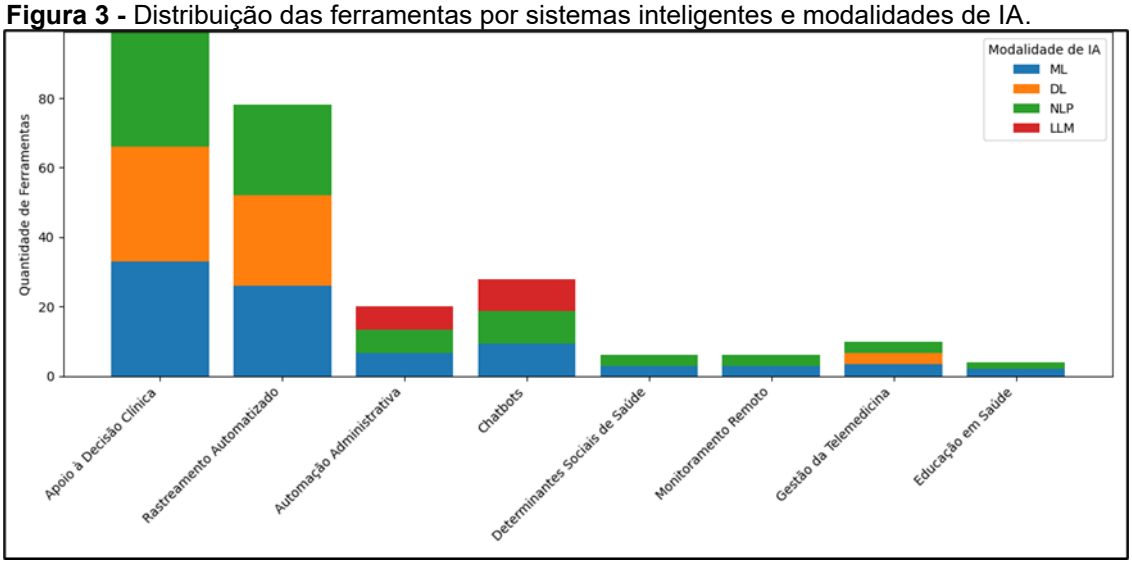
APOIO À DECISÃO CLÍNICA (ML, DL e NLP)
ML: algoritmos com dados rotulados; **DL**: imagens médicas complexas; **NLP**: notas clínicas não estruturadas
AUTOR/ANO
Dos Santos J, et al. (2025); Geersing G, et al. (2025); Goldberg DG, et al. (2025); Hancox Z, et al. (2025); Hathaway E, et al. (2025); Hill J, et al. (2025); Hurt RT, et al. (2025); Jin-Hyun P, et al. (2025); Kurasawa H, et al. (2025); Majeed A, et al. (2025); Park JW, et al. (2025); Pinho STR, et al. (2025); Rudge A, et al. (2025); Tibble H, et al. (2025); Thomsen CHN, et al. (2025); Von Bahr C, et al. (2025); Zheng M, et al. (2025); Wallensten J, et al. (2025); Wändell P, et al. (2025); Weissenbacher D, et al. (2025); Allen R, et al. (2024); Catalina QM, et al. (2024); Chen A, et al. (2024); Cook N, et al. (2024); Costa AJ, et al. (2024); Daniel R, et al. (2024); Dormosh N, et al. (2024); Feng W, et al. (2024); Hamid MMA, et al. (2024); Helenason J, et al. (2024); Janssens A, et al. (2024); Leung E, et al. (2024); Papunen I, et al. (2024); Ruge T et al. (2024); Salet N, et al. (2024); Song W, et al. (2024); Talker L, et al. (2024); Tesfaye SH, et al. (2024); Vordenberg SE, et al. (2024); Wang L, et al. (2024); Worker A, et al. (2024); Castel-Feced S, et al. (2023); Danda G, et al. (2023); Dormosh N, et al. (2023); Escalé-Besa A, et al. (2023); Frischen LS, et al. (2023); Funnell JP, et al. (2023); Granviken F, et al. (2023); Guida F, et al. (2023); Hanson RF, et al. (2023); Hareendranathan, A, et al. (2023); Hassan AE, et al. (2023); Himmelreich JCL e Harskamp RE (2023); Kany S, et al. (2023); Lapi F, et al. (2023); Kennedy J, et al. (2023); MacLagan LC, et al. (2023); Manzanet JMP, et al. (2023); Rao A e Manley L, et al. (2023); Parham GP, et al. (2023); Rojek I, et al. (2023); Smith S, et al. (2023); Steerling E, et al. (2023); Szlejf C, et al. (2023); Wickramasinghe N, et al. (2023); Zhang P, et al. (2023); Adams J (2022); Ashburner JM, et al. (2022); Barry B, et al. (2022); Bennis FC, et al. (2022); Buck C, et al. (2022); Chen N, et al. (2022); Herter WE; et al. (2022); Hill NR, et al. (2022); Knoop J, et al. (2022); Kurstjens S, et al. (2022); Mejerian JT, et al. (2022); Papini S, et al. (2022); Rushlow DR, et al. (2022); Sae-Ang A, et al. (2022); Sajeev S, et al. (2022); Song C, et al. (2022); Wang Y, et al. (2022); Zafari H, et al. (2022); Zhang Q, et al. (2022); Byeon H, et al. (2021); Dolgikh S, et al. (2021); Haun MW, et a. (2021); Hendrix N, et al. (2021); Malhotra A, et al. (2021); Nemesure MD, et al. (2021); Seol HY, et al. (2021); Wang J, et al. (2021); Zafari H, et al. (2021); Baghel N, et al. (2020); Bhuiyan A et al. (2020); Entezarjou A, et al. (2020); Romero-Brufau S, et al. (2020); Shih CC, et al. (2020)
RASTREAMENTO AUTOMATIZADO (ML, DL, NLP)
ML: classificação com dados rotulados ou agrupamento de risco sem rótulos prévios; DL: interpretar dados visuais complexos; NLP: textos clínicos livres
AUTOR/ANO
Beals D, et al. (2025); Bhambhwani V, et al. (2025); Esmaeilkhanian H, et al. (2025); Ferris LK, et al. (2025); Jan CL, et al. (2025); Krogh M, et al. (2025); Li Q, et al, (2025); Martin RN, et al. (2025); Mazur A, et al. (2025); Wändell P, et al (2025); Yuan J, et al. (2025); Zaman M, et al. (2025); Zulu N, et al. (2025); Baget-Bernaldiz M, et al. (2024); Bonfim RA (2024); Bridges A, et al. (2024); Cheng WHG, et al. (2024); Clift AK, et al. (2024); Costa O e Gouveia LB, et al. (2024); Dos Reis MA, et al. (2024); Ghadiri P, et al. (2024); Gu C, et al. (2024); Huang JJ, et al. (2024); Ji L, et al. (2024); Levésque P, et al. (2024); Li JL, et al. (2024); Liu TY, et al. (2024); McKinlay G, et al. (2024); Menon SV, et al. (2024); Papachristou P, et al. (2024); Quiter EEV, et al. (2024); Raldow AC, et al. (2024); Shaikh N, et al. (2024); Stuermer L, et al. (2024); Venkatesh KP, et al. (2024); Voltan G, et al. (2024); Zhang X, et al. (2024); Abascal JPV, et al. (2023); Ahluwalia VS, et al. (2023); Compton EC, et al. (2023); Dow ER, et al. (2023); Ellertsson S, et al. (2023); Hang H, et al. (2023); Kemp O, et al. (2023); Kinaszczuk A, et al. (2023); Jidling, C, et al. (2023); Liu S, et al. (2023); Miller IJ, et al. (2023); Nemlander E, et al. (2023); Nolan B, et al. (2023); Scanzera AC, et al. (2023); Wewetzer LZ, et al. (2023); Zhou Y, et al. (2023); Blanes-Vidal V, et al. (2022); Dong X et al. (2022); Dross JT, et al. (2022); Fuller SD, et al. (2022); Held LA, et al. (2022); Herman B, et al. (2022); Liu L, et al. (2022); Liu X, et al. (2022); Raat W, et al. (2022); Ruamviboonsuk P, et al. (2022); Amit G, et al. (2021); Aponte-Hao S, et al. (2021); Carvalho LND, et al. (2021); Crutzen S, et al. (2021); Herman B, et al. (2021); Ipp E, et al. (2021); Lee AY, et al. (2021); Li Y, et al. (2021); Liu J, et al. (2021); Ming S, et al. (2021); Shah A, et al. (2021); Takamine L, et al. (2021); Cuadros J (2020); Doyle OM, et al. (2020); Shimpi N, et al. (2020)
AUTOMAÇÃO DE PROCESSOS ADMINISTRATIVOS (ML, NLP e LLM)
ML: clustering e regras para otimizar fluxos e detectar padrões; **NLP**: notas não estruturadas; **LLM**: processar grandes volumes de texto não estruturado para gerar respostas coerentes em linguagem natural.

AUTOR/ANO
AlSerkal YM, et al. (2025); Bakke A, et al. (2025); Ha E, et al. (2025); Menchaca JT, et al. (2025); Rajaram A, et al. (2025); Tuan WJ, et al. (2025); Andrew A, et al. (2024); Liley J, et al. (2024); Liu T, et al. (2024); Rahmanti, AR, et al. (2024); Seinen TM, et al. (2024); Siira E, et al. (2024); Vallès-Peris N e Pareto J, et al. (2024); Waheed MA e Liu L, et al. (2024); Harris JE, et al. (2023); Holm S (2023); Tejedor M, et al. (2023); Ställberg B, et al. (2021); Xavier EC, et al. (2021); Hsu CN, et al. (2020)
CHATBOTS (NLP, LLM e ML)
NLP: interpretam linguagem natural; **LLM:** ampliar capacidade de interação contextualizada; **ML:** compreender descrições textuais rotuladas, ou não, para associar sintomas e patologias
AUTOR/ANO
Armitage RC (2025); Castro VM, et al. (2025); Moschogianis S, et al. (2025); Shemtob L et al. (2025); Tu T, et al. (2025); Zhuang S, et al. (2025); Blease CR, et al (2024); Chen F, et al. (2024); Govender I, et al. (2024); Holt-Quick C (2024); Khan H, et al. (2024); Owens LM, et al. (2024); Peterson JF, et al. (2024); Reyes DM, et al. (2024); Rodrigues RR, et al. (2024); Sandreschi PF, et al. (2024); Seth P, et al. (2024); Small WR, et al. (2024); Wallnöfer A, et al. (2024); Daher M, et al. (2023); Delsoz M, et al. (2023); Mahlknecht A, et al (2023); Nayak A, et al (2023); Wiedermann CJ et al (2023); Hong G, et al. (2022); Olano-Espinosa E, et al. (2022); Eisman AS, et al. (2020); Miller S, et al. (2020)
GERENCIAMENTO DOS DETERMINANTES SOCIAIS DE SAÚDE (ML e NLP)
ML: geralmente com uso de redes neurais para análises complexas **NLP:** análise de registros não estruturados
AUTOR/ANO
Davis VH, et al. (2025); Holt S, et al. (2025); Garies S, et al. (2024); Moon S (2024); Leung E, et al. (2023); Kueper JK, et al. (2022)
MONITORAMENTO REMOTO (ML e NLP)
ML: uso de modelagem de padrões complexos e dinâmicos de dados estruturados ou não presentes em dados clínicos; **NLP**: análise de dados não estruturados.
AUTOR/ANO
De Oliveira, EL e De Farias CM (2025); Mohan D, et al. (2025); Andrews RJ, et al. (2024); Yao Y, et al. (2024); Jaklitsch E, et al. (2023); Schäfer S, et al. (2023)
GESTÃO DE TELEMEDICINA (ML, NLP e DL)
ML: algoritmos com dados estruturados ou não para triagem remota e suporte diagnóstico; **NLP:** análise de dados não estruturados de prontuários; DL: análise de características visuais complexas das imagens clínicas.
AUTOR/ANO
Lamem MFH e Ahmed MISA, et al (2025); Yoshihara H, et al. (2025); Andrews RJ, et al. (2024); Bradford L (2024); Keshavjee K, et al. (2024); Wu X, et al. (2024); Min S, et al. (2023); Bhuiyan A, et al. (2021); Blease C, et al. (2021); Giavina-Bianchi M, et al. (2021)
EDUCAÇÃO EM SAÚDE (NLP e ML)
ML: dados estruturados ou não para extração de conteúdos educativos personalizados; **NLP:** interpretar linguagem natural e adaptar mensagens ao perfil do paciente ou profissional.
AUTOR/ANO
Geersing G, et al. (2025); Bowman MA, et al. (2024); Gilfoyle M, et al. (2024); Ellertsson S, et al. (2021)

Legenda: ML – Machine Learning; DL – Deep Learning; NLP - *Natural Language Processing; LLM – Large Language Models.*
Fonte: Oliveira Junior JG e Pedroso MM, 2026.

Os achados ainda demonstram que a eficácia dos sistemas inteligentes na APS reside na convergência entre *Machine Learning* (ML) e *Natural Language Processing* (NLP). O uso de ML permite o processamento de grandes volumes de dados, enquanto o NLP atende ao crescente interesse na análise de textos clínicos livres — como prontuários e anotações —, automatizando tarefas documentais e interpretando a linguagem humana. Em cenários de maior complexidade, o *Deep Learning* (DL) amplia a precisão no reconhecimento de padrões em exames de imagem e sinais, sendo fundamental para o apoio à decisão e rastreamento automatizado. Complementarmente, a evolução dos chatbots e da automação administrativa é impulsionada por *Large Language Models* (LLM), que possibilitam análise semântica avançada e interações mais contextualizadas e personalizadas com os pacientes (**Figura 3**).

Figura 3 - Distribuição das ferramentas por sistemas inteligentes e modalidades de IA.



Fonte: Oliveira Junior JG e Pedroso MM, 2026.

DISCUSSÃO

Geografia da Inovação: Assimetrias e Convergências Globais no Uso da IA na APS

A análise revela uma "especialização contextual" na aplicação da IA, onde as prioridades refletem as lacunas dos sistemas locais. No **Norte Global** (EUA, Reino Unido, Canadá e Escandinávia), a IA é posicionada como resposta à crise de recursos humanos e ao *burnout*. Pesquisas focam no uso de NLP e LLM para automatizar a documentação clínica — atuando como "escribas digitais" (BRESSAN T, et al., 2025) — e no emprego de ML para gerir multimorbidades e prever riscos em populações envelhecidas (DORMOSH N, et al., 2024).

Em contraste, no **Sul Global** (América Latina, África e Sudeste Asiático), a tecnologia atua como um "equalizador de acesso", levando diagnósticos especializados a áreas remotas, superando a escassez crônica de especialistas. Observa-se o fenômeno do *leapfrogging* tecnológico — quando sistemas de saúde saltam etapas tradicionais de infraestrutura para adotar inovações de ponta, como o uso de smartphones com DL para triagem e rastreamento de doenças em áreas remotas (PARHAM GP, et al., 2023). O Brasil destaca-se neste cenário pela vigilância epidemiológica e rastreamento especializado em regiões desassistidas (BORGES DGF, et al., 2025; GIAVINA-BIANCHI M, et al., 2021).

A China apresenta um modelo híbrido de escala continental, integrando IA em exames de rotina para "triagem oportunista" em massa, combinando a eficiência do Norte com a busca por cobertura universal do Sul (JI L, et al., 2024).

Apesar das disparidades na aplicação da IA, há uma convergência global nas barreiras à implementação: a confiança no algoritmo, a ética no uso de dados e o letramento digital dos profissionais são desafios transversais (KARAMI M e MADLOOL H, 2025). Independentemente do contexto socioeconômico, a literatura reforça que a efetividade da IA depende de governança local e adaptação cultural (STEERLING E, et al., 2025).

Áreas de Aplicação e Prioridades de Pesquisa

A literatura revela que a IA na APS prioriza o rastreamento automatizado e o apoio à decisão clínica, com domínio da oftalmologia e dermatologia. O uso de Visão Computacional (DL) e ML para triagem de retinopatia diabética é a intervenção mais consolidada para ampliar a equidade em populações desassistidas (RUAMVIBOONSUK P, et al., 2022). Na dermatologia, algoritmos para detecção de melanoma oferecem suporte a generalistas, embora enfrentem desafios de especificidade em cenários reais (FERRIS LK, et al., 2025). Cresce também o uso de ML para estratificação de risco cardiovascular e metabólico, utilizando dados de prontuários eletrônicos (WÄNDELL P, et al., 2025).

No campo comunicacional e administrativo, chatbots e Modelos de LLMs automatizam a documentação clínica e orientam pacientes sobre sintomas, mitigando o *burnout* profissional e otimizando fluxos organizacionais (BRESSAN T, et al., 2025). Essas soluções executam atividades repetitivas — como agendamentos, envio de lembretes e atualização documental — diminuindo a carga burocrática das equipes e ampliando o tempo para o cuidado direto. Integradas à lógica da gestão operacional, tais ferramentas fortalecem a coordenação entre níveis assistenciais e favorecem ações preventivas no território (MAYER MA, 2023).

A educação em saúde é impulsionada por soluções como a S.A.R.A.H. (*Smart AI Resource Assistant for Health*), assistente da OMS que utiliza IA generativa para interagir em múltiplos idiomas sobre diversos temas de saúde (KARAMI M e MADLOOL H, 2025). Paralelamente, emergem ferramentas para gestão de determinantes sociais, capazes de mapear vulnerabilidades comunitárias sem sobrecarregar o registro manual (GARIES S, et al., 2024; MAYER MA, 2023), e sistemas de monitoramento remoto via dispositivos vestíveis, que permitem intervenções precoces em doenças crônicas (SMOKOVSKI I, et al., 2024). Essas abordagens reduzem deslocamentos desnecessários e priorizam atendimentos presenciais para casos mais complexos. Por fim, a IA otimiza a telemedicina e a gestão logística, embora sua eficácia em regiões remotas dependa de conectividade estável para não ampliar o "fosso digital" (BRESSAN T, et al., 2025).

Percepções de Profissionais e Pacientes

A aceitação da IA na APS é marcada por um "otimismo cauteloso". Profissionais reconhecem ganhos em eficiência e precisão, mas temem a perda de autonomia, o aumento da carga cognitiva e a desumanização do cuidado (RAZAI MS, et al., 2024). Há um receio recorrente de que modelos de "caixa-preta" (pouco explicáveis) gerem uma tutela algorítmica (RAZAI MS, et al., 2024) e o fenômeno do *deskilling* — processo em que a automação de tarefas formativas reduz gradualmente as habilidades especializadas do clínico (UPSHAW TL, et al., 2023). Assim, a confiança na tecnologia depende da explicabilidade e da validação humana antes da aplicação prática (STEERLING E, et al., 2025).

No campo relacional, teme-se que interfaces excessivamente mediadoras comprometam o vínculo terapêutico e a escuta ativa (COOPER J, et al., 2025). Essas percepções moldam o ritmo de incorporação das soluções no cotidiano da APS (MOSCHOGIANIS S, et al., 2025; VIDAL-ALABALL J, et al., 2024).

Por outro lado, a visão dos pacientes é pragmática: há abertura para a IA se esta acelerar triagens e diagnósticos (NOLAN BM, et al., 2023). Contudo, idosos e pessoas com menor letramento digital tendem a preferir a validação final do médico de família (VORDENBERG SE, et al., 2024). A disposição para seguir recomendações é influenciada pela legitimidade do emissor (humano ou máquina) e pelo benefício direto percebido, como a redução de procedimentos invasivos e a economia de tempo (GARIES S et al., 2024). Persiste, porém, o receio de que decisões mediadas predominantemente por sistemas inteligentes provoquem o afastamento do cuidado humano direto (MAYER MA, 2023).

Barreiras e Necessidades para Adoção Efetiva

Para que a IA transite da pesquisa para a prática rotineira na APS, a interoperabilidade e a qualidade dos dados são os gargalos técnicos mais urgentes. A fragmentação dos sistemas impede a alimentação de modelos preditivos robustos (KUEPER JK, et al., 2022).

Soma-se a isso a falta de validação externa em cenários reais: muitas ferramentas performam com excelência *in silico* — experimentos realizados via simulação computacional —, mas falham diante da "sujeira" e heterogeneidade dos dados clínicos da APS (MILLER et al., 2023). Essa discrepância impõe limites severos à generalização dos resultados para a prática cotidiana, sugerindo que modelos treinados em bases de dados altamente curadas podem não ser seguros ou eficazes quando expostos à heterogeneidade das populações atendidas na APS.

Do ponto de vista organizacional, a integração ao *workflow* é determinante. Soluções que rompem a dinâmica da consulta são rejeitadas, tornando o "design centrado no usuário" essencial para superar a resistência a implementação (GOLDBERG DG, et al., 2025).

Estruturalmente, a disponibilidade de equipamentos e conectividade estável são pilares que, se distribuídos de forma desigual, podem aprofundar disparidades em saúde (BRESSAN T, et al., 2025). As experiências documentadas sugerem que iniciativas eficazes começam pela avaliação criteriosa da infraestrutura existente antes da implantação propriamente dita (JONES OT, et al., 2025).

Todavia, a infraestrutura deve ser acompanhada pelo preparo técnico das equipes, visando um uso crítico, seguro e contextualizado (BRESSAN T, et al., 2025). Esse preparo deve abranger tanto profissionais envolvidos no cuidado quanto equipes técnicas de suporte, assegurando que todos interajam com as ferramentas dentro de parâmetros seguros (KHAN H e BOKHARI SFH, 2024). Não se trata apenas de adquirir habilidades operacionais básicas, mas de consolidar um repertório que permita integrar a tecnologia de forma segura, crítica e contextualizada à prática clínica cotidiana (SIIRA E, et al., 2024).

A adoção efetiva também exige marcos normativos que garantam a transparência algorítmica e definam responsabilidades claras entre desenvolvedores, gestores e clínicos em casos de incidentes. É imprescindível a definição clara de responsabilidade sobre erros de diagnósticos ou conduta inadequada sugerida pelo sistema. Deve haver previsão explícita sobre o papel do desenvolvedor, do gestor institucional e do usuário clínico na apuração e resolução do incidente (KHAN H e BOKHARI SFH, 2024).

A proteção contra ciberataques e a avaliação contínua de desempenho completam o ciclo de segurança necessário para o uso prolongado dessas tecnologias. Logo, a avaliação contínua é um componente crítico para garantir a efetividade e a segurança dessas tecnologias. Trata-se de um processo que deve acompanhar o ciclo operacional do sistema desde sua implantação, permitindo ajustes dinâmicos tanto nos parâmetros técnicos quanto nos fluxos clínicos nos quais esteja inserido (MAYER MA, 2023).

Implicações Éticas e socioculturais

A privacidade e a segurança dos dados são preocupações centrais, alimentadas pelo receio de usos indevidos, como a discriminação por seguradoras, e por experiências negativas prévias com sistemas digitais falhos (NASH DM, et al., 2023). Soma-se a isto o debate sobre a propriedade dos dados, onde a comercialização de informações por fornecedores de prontuários eletrônicos levanta dilemas sobre transparência e consentimento (TERRY AL, et al., 2022).

Mas as implicações éticas transcendem a privacidade, incidindo sobre a equidade e a justiça algorítmica. O treino de modelos em bases de dados não representativas pode exacerbar disparidades socioeconômicas e raciais, questionando a legitimidade de decisões automatizadas que penalizam grupos vulneráveis (DARCEL K, et al., 2023). Além disso, há o risco da automação excessiva comprometer a longitudinalidade e o vínculo terapêutico, reduzindo o profissional a um "alimentador de dados" e invisibilizando determinantes sociais que a IA ainda não captura plenamente (VALLÈS-PERIS N e PARETO J, 2025).

Em contextos que privilegiam o contato humano como expressão de empatia, a mediação tecnológica pode ser interpretada como um enfraquecimento relacional (RAZAI MS, et al., 2024). Profissionais também manifestam cautela face ao possível deslocamento da sua autonomia para uma "autoridade" tecnológica. Em categorias médicas historicamente pautadas por autonomia na tomada de decisão, a inserção de algoritmos preditivos ou sistemas de apoio clínico é recebida com cautela quando há receio de deslocamento do papel do médico para atuante secundário frente à “autoridade” tecnológica (BRESSAN T, et al., 2025).

No entanto, há ainda casos nos quais o uso da IA encontra ressonância positiva em padrões culturais específicos. Comunidades habituadas ao emprego cotidiano de serviços digitais (plataformas bancárias online, compras virtuais ou comunicação via aplicativos móveis) tendem a absorver com mais naturalidade soluções tecnológicas aplicadas à saúde (COOPER J, et al., 2025). Nesses cenários, a IA é percebida como extensão lógica dos recursos já disponíveis no cotidiano, favorecendo experimentação voluntária das ferramentas propostas. Entretanto, mesmo nesses contextos “digitalmente fluentes”, fatores como privacidade dos dados e clareza na origem das informações mantêm peso relevante na avaliação final sobre adesão (GARIES S, et al., 2024).

Caminhos e Estratégias de Implementação

A viabilização da IA em larga escala na APS exige uma abordagem sistêmica baseada em educação, governança e *co-design*. É imperativo desenvolver a "alfabetização em IA", capacitando profissionais para além da operação técnica, permitindo uma avaliação crítica dos resultados algorítmicos (CATALINA QM, et al., 2023). A implementação deve ser gradual, iniciando por projetos-piloto em ambientes controlados que permitam a assimilação cultural e o ajuste de fluxos antes da expansão (BARRY B, et al., 2022).

Estratégias bem-sucedidas envolvem o engajamento de stakeholders (profissionais, pacientes e gestores) como co-desenhadores das ferramentas (MAYER MA, 2023), garantindo que a tecnologia atue como "Inteligência Aumentada" para apoiar — e não substituir — o julgamento clínico (TAN NC, et al., 2025).

Financeiramente, a literatura aponta as Parcerias Público-Privadas (PPP) como mecanismos para superar lacunas estruturais, permitindo o compartilhamento de riscos e investimentos (BRESSAN T et al., 2025). Tais parcerias devem ser acompanhadas de incentivos, como subsídios para atualização tecnológica e fundos permanentes para treinamento continuado, prevenindo a obsolescência acelerada (JONES OT, et al., 2025). Ao permitir compartilhamento de responsabilidades e investimentos, as PPP podem reduzir o peso orçamentário sobre governos, especialmente em regiões onde o gasto público em saúde é proporcionalmente baixo frente à média nacional (VALLÈS-PERIS N e PARETO J, 2025). Incentivos financeiros são catalisadores dessa transição tecnológica. Outros formatos incluem subsídios diretos para aquisição de equipamentos compatíveis com as plataformas inteligentes, créditos fiscais para instituições que comprovem uso consistente das soluções e repasses vinculados ao alcance de metas específicas relacionadas à qualidade do cuidado apoiado por tecnologia (RAZAI MS, et al., 2024).

Por fim, a consolidação de uma mentalidade orientada a dados (*data-driven*) requer marcos regulatórios claros, pautados pela transparência, explicabilidade e supervisão humana obrigatória (TRONCOSO EL, 2020). Referenciais internacionais, como o *AI Act* europeu e as normas ISO de proteção da informação, oferecem bases sólidas para diretrizes nacionais que assegurem a conformidade técnica e ética dos fornecedores no SUS (DE OLIVEIRA EL e DE FARIAS MC, 2025).

Limitações do estudo

Devem-se reconhecer as limitações desta revisão: a exclusão de conteúdos restritos pode ter omitido evidências de alto impacto ou inovações proprietárias. O panorama reflete, portanto, a ciência aberta e colaborativa. Embora a amostra seja robusta, revisões futuras devem incluir bases pagas para capturar inovações de nicho ou estudos industriais retidos sob *paywalls* institucionais.

CONSIDERAÇÕES FINAIS

A presente revisão evidencia que a IA na APS atravessa um momento de inflexão: a transição da validação *in silico* para a implementação pragmática. Os dados demonstram maturidade técnica para o suporte à decisão e triagem, especialmente em áreas de reconhecimento de padrões como oftalmologia e dermatologia. Contudo, a adoção em larga escala depende, não somente do aprimoramento da acurácia algorítmica, mas também da superação de barreiras da qualidade dos dados, interoperabilidade e da aceitação cultural de equipes e pacientes. A convergência entre DL e ML aponta para um novo paradigma de APS preditiva e personalizada. O processamento de grandes volumes de dados de prontuários permite identificar

precocemente deteriorações clínicas e surtos epidemiológicos, otimizando a vocação preventiva do nível primário. Mas, para que essa promessa se concretize, a tecnologia deve reduzir a carga cognitiva burocrática, permitindo que o tempo economizado seja reinvestido no vínculo terapêutico. A introdução destas ferramentas na APS deve ser compreendida como um processo integrado que combina avanços técnicos com compromisso ético-social, diálogo interdisciplinar e respeito às especificidades culturais. Conclui-se que a "Inteligência Aumentada" deve ser governada por princípios de equidade e transparência, atuando como uma "segunda opinião" que empodera, e não substitui, a humanidade do médico de família. Pesquisas futuras devem migrar do foco exclusivo no desempenho técnico para estudos longitudinais de implementação no mundo real, avaliando custo-efetividade e satisfação do usuário. Somente assim a IA deixará de ser uma promessa futurista para se tornar um instrumento cotidiano de justiça social e acesso à saúde.

REFERÊNCIAS

1. BARRY B, et al. Provider Perspectives on Artificial Intelligence–Guided Screening for Low Ejection Fraction in Primary Care: Qualitative Study. JMIR AI, 2022; 1(1): e41940.
2. BORGES DGF, et al. Combining machine learning and dynamic system techniques to early detection of respiratory outbreaks in routinely collected primary healthcare records. BMC Medical Research Methodology, 2025; 25(1): 99.
3. BRAUN V, CLARKE, V. Successful Qualitative Research a practical guide for beginners. 1st ed. SAGE: Los Angeles – LA, London – LCY, New Delhi, NCT, Singapore, SGP e Washington, DC, 2013; p173.
4. BRESSAN T, et al. AI scribes in rural and remote primary care: an antidote to physician burnout or Pandora's Box? Rural and Remote Health, 2025; 25: 9430.
5. CATALINA QM, et al. Knowledge and perception of primary care healthcare professionals on the use of artificial intelligence as a healthcare tool. DIGITAL HEALTH, 2023; 9: 20552076231180511.
6. COOPER J, et al. Perspectives of Health Care Professionals on the Use of AI to Support Clinical Decision-Making in the Management of Multiple Long-Term Conditions: Interview Study. Journal of Medical Internet Research, 2025; 27: e71980.
7. DARCEL K, et al. Implementing artificial intelligence in Canadian primary care: Barriers and strategies identified through a national deliberative dialogue. PLOS ONE, 2023; 18(2): e0281733.
8. DE OLIVEIRA EL e DE FARIAS MC. TWINVAX: conceptual model of a digital twin for immunisation services in primary health care. Frontiers in Public Health, 2025; (13): 1568123.
9. DORMOSH N, et al. Topic evolution before fall incidents in new fallers through natural language processing of general practitioners' clinical notes. Age and Ageing, 2024; 53(2): p. afae016.
10. FERRIS LK, et al. DERM-SUCCESS FDA Pivotal Study: A Multi-Reader Multi-Case Evaluation of Primary Care Physicians' Skin Cancer Detection Using AI-Enabled Elastic Scattering Spectroscopy. Journal of primary care & community health, 2025; 16: 1–9.
11. GARIES S, et al. Artificial intelligence in primary care practice: Qualitative study to understand perspectives on using AI to derive patient social data. Canadian Family Physician, 2024; 70(7–8): e102–e109.
12. GIAVINA-BIANCHI M, et al. Implementation of artificial intelligence algorithms for melanoma screening in a primary care setting. PLOS ONE, 2021; 16(9): e0257006.
13. GOLDBERG DG, et al. Clinicians' perspectives on the adoption and implementation of EMR-integrated clinical decision support tools in primary care. DIGITAL HEALTH, 2025; (11): 20552076251334043.
14. JI L, et al. Performance of a Full-Coverage Cervical Cancer Screening Program Using on an Artificial Intelligence– and Cloud-Based Diagnostic System: Observational Study of an Ultralarge Population. Journal of Medical Internet Research, 2024; 26: e51477.
15. JONES OT, et al. User and Developer Views on Using AI Technologies to Facilitate the Early Detection of Skin Cancers in Primary Care Settings: Qualitative Semistructured Interview Study. JMIR Cancer, 2025; 11: e60653.
16. KARAMI M e MADLOOL H. Artificial intelligence and digital health in the health systems of developing countries: the challenges and vision of integration in the primary health care setting. Frontiers in Digital Health, 2025; 7: 1532361.
17. KHAN H e BOKHARI SFH. Integrating Artificial Intelligence (AI) Chatbots for Depression Management: A New Frontier in Primary Care. Cureus, 2024; 16(8): e66857

18. KUEPER JK, et al. Connecting artificial intelligence and primary care challenges: findings from a multi stakeholder collaborative consultation. BMJ Health & Care Informatics, 2022; 29(1): e100493.
19. LI J, et al. Integrated image-based deep learning and language models for primary diabetes care. Nature Medicine, 2024; 30(10): 2886–2896.
20. MAYER MA. Inteligencia artificial en atención primaria: un escenario de oportunidades y desafíos. Atención Primaria, 2023; 55(11): 102744.
21. MILLER IJ, et al. Implementation of artificial intelligence for the detection of cutaneous melanoma within a primary care setting: prevalence and types of skin cancer in outdoor enthusiasts. PeerJ,2023; 11: e15737.
22. MOSCHOGIANIS S, et al. Seven Opportunities for Artificial Intelligence in Primary Care Electronic Visits: Qualitative Study of Staff and Patient Views. The Annals of Family Medicine, 2025; 23(3): 214–222.
23. NASH DM, et al. Perceptions of Artificial Intelligence Use in Primary Care: A Qualitative Study with Providers and Staff of Ontario Community Health Centres. The Journal of the American Board of Family Medicine, 2023; 36(2): 221–228.
24. NOLAN BM, et al. Patient and Provider Experience with Artificial Intelligence Screening Technology for Diabetic Retinopathy in a Rural Primary Care Setting. Journal of Maine Medical Center, 2023; 5(2): doi:10.46804/2641-2225.1144
25. PARHAM GP, et al. Validation in Zambia of a cervical screening strategy including HPV genotyping and artificial intelligence (AI)-based automated visual evaluation. Infectious Agents and Cancer, 2023; 18(1): 61.
26. RAZAI MS, et al. Implementation challenges of artificial intelligence (AI) in primary care: Perspectives of general practitioners in London UK. PLOS ONE, 2024; 19(11): e0314196.
27. RUAMVIBOONSUK P, et al. Real-time diabetic retinopathy screening by deep learning in a multisite national screening programme: a prospective interventional cohort study. The Lancet Digital Health, 2022; 4 (4): e235–e244.
28. SIIRA E, et al. Healthcare leaders' experiences of implementing artificial intelligence for medical history-taking and triage in Swedish primary care: an interview study. BMC Primary Care, 2024; 25(1): 268.
29. SMOKOVSKI I, et al. Digital biomarkers: 3PM approach revolutionizing chronic disease management — EPMA 2024 position. EPMA Journal, 2024; 15(2): 149–162.
30. SOUZA MT, et al. Integrative review: what is it? How to do it? Einstein, 2010; 8 (1): 102–106.
31. STEERLING E, et al. Influences on trust in the use of AI-based triage—an interview study with primary healthcare professionals and patients in Sweden. Frontiers in Digital Health, 2025; 7: 1565080.
32. TAN NC, et al. Supporting quadruple aim in primary care using artificial intelligence. Annals of the Academy of Medicine, Singapore, 2025; 54(5): 305–309.
33. TERRY AL, et al. Is primary health care ready for artificial intelligence? What do primary health care stakeholders say? BMC Medical Informatics and Decision Making, 2022; 22(1): 237.
34. TRONCOSO EL. The Greatest Challenge to Using AI/ML for Primary Health Care: Mindset or Datasets? Frontiers in Artificial Intelligence, 2020; 3: 53.
35. UPSHAW TL, et al. Priorities for Artificial Intelligence Applications in Primary Care: A Canadian Deliberative Dialogue with Patients, Providers, and Health System Leaders. The Journal of the American Board of Family Medicine, 2023; 36 (2): 210–220.
36. VALLÈS-PERIS N e PARETO J. Artificial intelligence as a mode of ordering. Automated-decision making in primary care. Information, Communication & Society, 2025; 28(11): 2015–2033.
37. VIDAL-ALABALL J, et al. The artificial intelligence revolution in primary care: Challenges, dilemmas and opportunities. Atención Primaria, 2024; 56(2): 102820.
38. VORDENBERG SE, et al. Investigating Older Adults' Perceptions of AI Tools for Medication Decisions: Vignette-Based Experimental Survey. Journal of Medical Internet Research, 2024; 26: e60794.
39. WÄNDELL P, et al. A machine learning tool for identifying newly diagnosed heart failure in individuals with known diabetes in primary care. ESC Heart Failure, 2025; 12(1): 613–621.
40. YOUNG RA, et al. What Complexity Science Predicts About the Potential of Artificial Intelligence/Machine Learning to Improve Primary Care. The Journal of the American Board of Family Medicine, 2024; 379(2): 332–345.