

Inteligência artificial na medicina: aplicações clínicas, benefícios, limitações e desafios éticos

Artificial intelligence in medicine: clinical applications, benefits, limitations, and ethical challenges

Maria Luiza Furtado Cutrim de Carvalho

Maria Clara Figueiredo Guimarães

Lucas Rosendo (Orientador)

RESUMO

A inteligência artificial (IA) tem emergido como uma tecnologia transformadora na medicina contemporânea, promovendo avanços significativos no diagnóstico, tratamento e gestão da saúde. Esta revisão integrativa da literatura teve como objetivo analisar as aplicações clínicas da IA na medicina, seus benefícios, limitações e desafios éticos. A pesquisa foi conduzida nas bases de dados PubMed, Scopus, Web of Science, Embase, SciELO e Biblioteca Virtual em Saúde, utilizando descritores DeCS/MeSH, abrangendo o período de 2021 a 2026. Foram incluídos 100 artigos que atenderam aos critérios de elegibilidade. Os resultados demonstram que a IA, especialmente por meio de machine learning e deep learning, tem revolucionado o diagnóstico por imagem em radiologia, dermatologia, cardiologia e oncologia, com acurácia comparável ou superior à de especialistas humanos em diversos cenários. Modelos de linguagem de grande porte, como o ChatGPT, apresentam potencial para auxiliar na educação médica, suporte à decisão clínica e telemedicina. No entanto, limitações técnicas, como a dependência de dados de treinamento de qualidade, o problema do viés algorítmico e a falta de explicabilidade dos modelos, representam barreiras significativas. Desafios éticos relacionados à privacidade de dados, responsabilidade médica, consentimento informado e equidade no acesso também foram

identificados. Conclui-se que, embora a IA ofereça imensas oportunidades para a medicina, sua implementação responsável requer governança robusta, regulamentação adequada e uma abordagem centrada no paciente que preserve a relação médico-paciente e os princípios bioéticos.

Palavras-chave: Inteligência Artificial. Medicina. Machine Learning. Ética Médica. Diagnóstico por Imagem.

ABSTRACT

Artificial intelligence (AI) has emerged as a transformative technology in contemporary medicine, promoting significant advances in diagnosis, treatment, and health management. This integrative literature review aimed to analyze the clinical applications of AI in medicine, its benefits, limitations, and ethical challenges. The research was conducted in the PubMed, Scopus, Web of Science, Embase, SciELO, and Virtual Health Library databases, using DeCS/MeSH descriptors, covering the period from 2021 to 2026. One hundred articles that met the eligibility criteria were included. The results demonstrate that AI, especially through machine learning and deep learning, has revolutionized diagnostic imaging in radiology, dermatology, cardiology, and oncology, with accuracy comparable to or superior to human specialists in various scenarios. Large language models, such as ChatGPT, show potential to assist in medical education, clinical decision support, and telemedicine. However, technical limitations, such as dependence on quality training data, algorithmic bias, and lack of model explainability, represent significant barriers. Ethical challenges related to data privacy, medical liability, informed consent, and equity in access were also identified. It is concluded that although AI offers immense opportunities for medicine, its responsible implementation requires robust governance, adequate regulation, and a patient-centered approach that preserves the doctor-patient relationship and bioethical principles.

Keywords: Artificial Intelligence. Medicine. Machine Learning. Medical Ethics. Diagnostic Imaging.

1 INTRODUÇÃO

A inteligência artificial (IA) constitui um dos avanços tecnológicos mais significativos do século XXI, com implicações profundas para diversos setores da sociedade contemporânea. No campo da saúde, particularmente na medicina, a IA tem emergido como uma ferramenta de transformação sem precedentes, redefinindo processos de diagnóstico, tratamento, prevenção e gestão de cuidados (ALOWAIS et al., 2023; ARAVAZHI et al., 2025). O conceito de inteligência artificial remonta à década de 1950, quando os cientistas John McCarthy, Marvin Minsky, Claude Shannon e Nathaniel Rochester propuseram a organização da Conferência de Dartmouth, considerada o marco fundacional do campo. Desde então, a área experimentou ciclos de entusiasmo e desilusão, até que, nas últimas duas décadas, fatores como o aumento exponencial da capacidade computacional, a disponibilidade de grandes volumes de dados digitais e o desenvolvimento de algoritmos sofisticados impulsionaram avanços sem precedentes (AHMAD et al., 2021; KARALIS, 2024).

O setor saúde gerou aproximadamente 2.314 exabytes de dados em 2020, com projeção de crescimento de 36% ao ano. Essa magnitude de informações, proveniente de prontuários eletrônicos, imagens médicas, registros genômicos, dispositivos wearables e outras fontes, supera a capacidade humana de processamento e análise, criando uma demanda urgente por ferramentas inteligentes de assistência à decisão clínica (TOPOL, 2019; AUNG et al., 2021). A pandemia de COVID-19 acelerou significativamente a adoção de tecnologias digitais em saúde. Estudos demonstraram que algoritmos de deep learning aplicados a imagens de tomografia computadorizada e radiografias de tórax alcançaram sensibilidade e especificidade superiores a 90% na detecção da doença, contribuindo para o diagnóstico em cenários de alta demanda (GHADERZADEH; ASADI, 2021; LIU et al., 2022).

No campo do diagnóstico por imagem, a IA demonstrou capacidade comparável ou superior à de radiologistas experientes em diversas tarefas. Aggarwal et al. (2021), em uma revisão sistemática e meta-análise, demonstraram que algoritmos de deep learning apresentam acurácia diagnóstica significativa em imagiologia médica. Najjar (2023) ressalta que a integração da IA em radiologia redefine o papel do especialista, transitando de mero intérprete de imagens para gestor de processos diagnósticos complexos. A medicina de precisão também tem se beneficiado substancialmente dos avanços em IA. Carini e Seyhan (2024) discutem como a IA multimodal integra dados genômicos, proteômicos,

metabolômicos e clínicos para desenvolver abordagens terapêuticas individualizadas. Modelos preditivos baseados em machine learning têm demonstrado sucesso na identificação de pacientes com maior probabilidade de resposta a determinados tratamentos oncológicos (KOLLA; PARIKH, 2024).

A emergência dos modelos de linguagem de grande porte (LLMs), como o ChatGPT, representa um novo paradigma na aplicação de IA à saúde. Dave, Athaluri e Singh (2023) descrevem as múltiplas aplicações do ChatGPT na medicina, desde assistência à redação científica até suporte à decisão clínica e educação médica. Thirunavukarasu et al. (2023) publicaram na *Nature Medicine* uma análise detalhada do potencial desses modelos, destacando tanto as oportunidades quanto os riscos. No entanto, a integração da IA na prática clínica não está isenta de desafios. Questões relacionadas ao viés algorítmico, privacidade de dados, responsabilidade médica, transparência dos modelos e segurança do paciente demandam atenção urgente (CHEN et al., 2023; ELENDU et al., 2023). Norori et al. (2021) argumentam que a falta de diversidade nos dados de treinamento pode perpetuar e amplificar disparidades existentes nos sistemas de saúde.

O Brasil, como país signatário de acordos internacionais de direitos humanos e proteção de dados, enfrenta o desafio de regulamentar o uso da IA em saúde de forma a promover a inovação sem comprometer os direitos fundamentais dos pacientes. A Lei Geral de Proteção de Dados (Lei nº 13.709/2018) estabelece diretrizes importantes, embora a regulamentação específica para aplicações médicas de IA ainda esteja em desenvolvimento. Diante desse cenário complexo e em rápida evolução, esta revisão integrativa da literatura justifica-se pela necessidade de síntese crítica do conhecimento científico atual sobre a IA na medicina, oferecendo uma visão abrangente das aplicações clínicas, benefícios, limitações e desafios éticos, com o objetivo de subsidiar profissionais de saúde, gestores, pesquisadores e formuladores de políticas públicas na tomada de decisões informadas sobre o uso dessa tecnologia transformadora.

2 REFERENCIAL TEÓRICO

2.1 Conceitos Fundamentais da Inteligência Artificial

A inteligência artificial pode ser definida como o campo da ciência da computação dedicado ao desenvolvimento de sistemas capazes de realizar tarefas que normalmente requerem inteligência humana, como percepção visual, reconhecimento de fala, tomada de

decisão e tradução entre idiomas (RUSSELL; NORVIG, 2021). O termo engloba um amplo espectro de técnicas e abordagens, desde sistemas baseados em regras até modelos de aprendizado profundo complexos. O aprendizado de máquina (machine learning) constitui um subconjunto da IA focado no desenvolvimento de algoritmos que permitem aos computadores aprender padrões a partir de dados, sem serem explicitamente programados para cada tarefa. Segundo Jordan e Mitchell (2015), o ML oferece ferramentas computacionais para tratamento de dados em larga escala, sendo particularmente relevante em domínios onde o volume de informações excede a capacidade de processamento humana.

Dentro do ML, o aprendizado profundo (deep learning) utiliza redes neurais artificiais com múltiplas camadas de processamento, capazes de extrair representações hierárquicas dos dados. LeCun, Bengio e Hinton (2015) demonstraram que essas arquiteturas revolucionaram campos como visão computacional e processamento de linguagem natural. Em medicina, o deep learning tem sido aplicado com sucesso em análise de imagens médicas, descoberta de fármacos e predição de desfechos clínicos. As redes neurais convolucionais (CNNs) representam a arquitetura predominante em análise de imagens médicas, enquanto as redes neurais recorrentes (RNNs) e suas variantes como LSTM são adequadas para análise de séries temporais, como sinais eletrocardiográficos e dados de monitoramento contínuo.

2.2 Evolução Histórica da IA na Saúde

A história da IA em saúde remonta às décadas de 1960 e 1970, com sistemas especialistas médicos como o DENDRAL, desenvolvido em 1965 para inferir estruturas moleculares, e o MYCIN, criado em 1976 para auxiliar no diagnóstico de infecções bacterianas e recomendação de antibioticoterapia (SHORTLIFFE, 1976). Embora esses sistemas tenham demonstrado desempenho comparável ao de especialistas humanos em domínios restritos, sua adesão clínica foi limitada por questões técnicas e de aceitação. A década de 1980 testemunhou o desenvolvimento de sistemas de apoio à decisão clínica (CDSS), integrados a prontuários eletrônicos para auxiliar na prescrição medicamentosa e diagnóstico diferencial.

No entanto, foi a partir de 2012, com o advento do deep learning e o sucesso da arquitetura AlexNet no desafio ImageNet, que a IA médica experimentou crescimento exponencial (KRIZHEVSKY et al., 2012). Entre 2015 e 2020, algoritmos de deep learning superaram especialistas humanos em tarefas específicas de diagnóstico por imagem. Estudos demonstraram que sistemas de IA alcançaram sensibilidade de 91% na detecção de

melanoma, comparável à de dermatologistas experientes. A pandemia de COVID-19 funcionou como catalisador para a adoção de IA em saúde, com desenvolvimento de modelos para detecção da doença em imagens de tórax e predição de gravidade em tempo recorde (YIN; NGIAM; TEO, 2021).




Figura 1 - Evolução Histórica da Inteligência Artificial na Medicina.

2.3 Machine Learning e Deep Learning

O machine learning compreende três paradigmas principais: aprendizado supervisionado, não supervisionado e por reforço. No aprendizado supervisionado, o algoritmo é treinado com pares de entrada-saída rotulados, aprendendo a mapear entradas para saídas corretas. Este é o paradigma mais comum em aplicações médicas diagnósticas (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). As redes neurais convolucionais (CNNs) representam a arquitetura de deep learning predominante em análise de imagens médicas. Zhou et al. (2021), em revisão publicada na Proceedings of the IEEE, descrevem como as CNNs extraem características hierárquicas de imagens, desde bordas simples em camadas iniciais até padrões complexos em camadas profundas.

Thakur et al. (2024) apresentam aplicações de deep learning em análise de imagens médicas, destacando avanços em radiologia e patologia. A técnica de transfer learning permite que modelos pré-treinados em grandes conjuntos de dados sejam adaptados para tarefas específicas com quantidades limitadas de dados. Candemir et al. (2021) discutem

estratégias de treinamento para modelos de deep learning em radiologia em cenários com dados limitados, demonstrando que o transfer learning é uma abordagem eficaz em contextos de escassez de dados anotados.

Figura 2 - Funcionamento do Machine Learning em Diagnóstico Médico




Figura 2 - Funcionamento do Machine Learning em Diagnóstico Médico.

2.4 Processamento de Linguagem Natural

O processamento de linguagem natural (NLP) é o campo da IA dedicado à interação entre computadores e linguagem humana. Em medicina, o NLP permite a extração automática de informações de prontuários eletrônicos não estruturados, conversão de relatórios médicos em dados estruturados e suporte a sistemas de busca em literatura científica (WANG; ZHANG, 2024). Alanazi (2023) descreve como o NLP, combinado com chatbots e sistemas especialistas, pode melhorar o diagnóstico através da extração de dados de registros médicos. Modelos de embeddings médicos, como o BioBERT e o ClinicalBERT, são variantes de arquiteturas transformer pré-treinadas em corpora biomédicos, permitindo representações semânticas ricas de termos médicos.

2.5 Inteligência Artificial Generativa

A inteligência artificial generativa refere-se a sistemas capazes de criar novo conteúdo, incluindo texto, imagens, áudio e código. Os modelos de linguagem de grande porte (LLMs), como o GPT-4 (ChatGPT), Claude e Gemini, representam a vanguarda dessa

tecnologia, demonstrando capacidades impressionantes de compreensão e geração de linguagem natural (THIRUNAVUKARASU et al., 2023). Dave, Athaluri e Singh (2023), em artigo publicado na *Frontiers in Artificial Intelligence*, apresentam uma visão abrangente das aplicações, vantagens, limitações e considerações éticas do ChatGPT na medicina. Sallam (2023), em revisão sistemática, avaliou o potencial do ChatGPT em educação médica, pesquisa e prática clínica, concluindo que o modelo oferece benefícios substanciais, mas requer uso responsável.

Shen et al. (2023), em artigo na *Radiology*, descrevem os LLMs como "espadas de dois gumes" em saúde, reconhecendo tanto o potencial transformador quanto os riscos associados ao uso inadequado. As preocupações incluem geração de informações incorretas (alucinações), viés nos dados de treinamento, questões de privacidade e impacto na relação médico-paciente. A necessidade de frameworks regulatórios específicos para IA generativa em saúde tem sido destacada por múltiplos autores, incluindo Meskó e Topol (2023).

2.6 IA e Big Data em Saúde

O conceito de Big Data em saúde refere-se ao volume, variedade e velocidade de dados gerados no setor, que excedem a capacidade de processamento de sistemas tradicionais. A integração de IA com Big Data permite análises preditivas, descoberta de padrões e personalização de cuidados em escala sem precedentes. Os dados em saúde apresentam características que os tornam particularmente desafiadores para análise: alta dimensionalidade, heterogeneidade, ruído, dados ausentes e questões de privacidade. Zeng, Huang e Zhu (2025) discutem como a IA multimodal integra dados de múltiplas fontes, incluindo registros eletrônicos de saúde, imagens médicas, genômica e dados de wearables.

O conceito de radiomics envolve a extração de centenas ou milhares de características quantitativas de imagens médicas, que podem ser analisadas por algoritmos de ML para predição de desfechos clínicos. Essa abordagem representa uma mudança de paradigma, transformando imagens médicas de ferramentas visuais subjetivas em dados quantitativos objetivos (BARNES et al., 2023). A medicina de precisão, impulsionada pela análise de Big Data, visa customizar tratamentos com base nas características individuais de cada paciente. Chen et al. (2025) exploram como a IA integra registros de saúde, genética e imunologia para medicina de precisão.

3 METODOLOGIA

3.1 Tipo de Estudo

Esta pesquisa configura-se como uma revisão integrativa da literatura, método que permite a síntese de múltiplos estudos com abordagens metodológicas variadas, possibilitando uma compreensão abrangente do fenômeno investigado. De acordo com Souza, Silva e Carvalho (2010), a revisão integrativa constitui a abordagem mais ampla de revisão de literatura, contemplando experimentais e não experimentais, com o propósito de sintetizar o conhecimento disponível e identificar lacunas na literatura científica.

3.2 Questão Norteadora

A questão norteadora desta revisão foi: "Quais são as aplicações clínicas da inteligência artificial na medicina, seus benefícios, limitações e desafios éticos, segundo a literatura científica publicada entre 2021 e 2026?"

3.3 Estratégia de Busca

A estratégia de busca seguiu o framework PICO (Population, Intervention, Comparison, Outcome), adaptado para revisões da literatura: População (pacientes em contextos de atenção à saúde); Intervenção (aplicações de inteligência artificial); Comparação (prática clínica convencional ou ausência de IA); Outcomes (desfechos clínicos, diagnósticos, éticos e organizacionais). As buscas foram realizadas nas seguintes bases de dados eletrônicas: PubMed/MEDLINE, Scopus, Web of Science, Embase, SciELO e Biblioteca Virtual em Saúde (BVS).

3.4 Descritores e Estratégia

Foram utilizados descritores estruturados segundo as terminologias DeCS (Descritores em Ciências da Saúde) e MeSH (Medical Subject Headings), combinados através dos operadores booleanos AND e OR: ("Artificial Intelligence" OR "Inteligência Artificial" OR "Machine Learning" OR "Deep Learning" OR "Neural Networks" OR "Natural Language Processing") AND ("Medicine" OR "Medicina" OR "Healthcare" OR "Saúde") AND ("Clinical Applications" OR "Aplicações Clínicas" OR "Diagnosis" OR "Diagnóstico" OR "Treatment" OR "Tratamento"). Descritores específicos para subtemas

incluiram: "Medical Imaging", "Radiology", "Precision Medicine", "Telemedicine", "Medical Education", "Medical Ethics", "Clinical Decision Support Systems", "ChatGPT", "Large Language Models" e "Algorithmic Bias".

3.5 Critérios de Inclusão

Foram incluídos artigos que atenderam aos seguintes critérios: (a) publicados entre janeiro de 2021 e março de 2026; (b) disponíveis em texto completo; (c) redigidos em inglês, português ou espanhol; (d) abordassem aplicações clínicas de IA na medicina; (e) apresentassem metodologia clara e resultados definidos; (f) publicados em periódicos indexados nas bases consultadas.

3.6 Critérios de Exclusão

Foram excluídos: (a) artigos duplicados em diferentes bases de dados; (b) cartas ao editor, editoriais e comentários de opinião; (c) resumos de eventos científicos sem publicação completa; (d) estudos sem descrição clara de metodologia; (e) artigos de acesso restrito não obtidos por interlibrary loan; (f) publicações em idiomas não contemplados nos critérios de inclusão.

3.7 Extração e Análise de Dados

Os dados extraídos dos artigos incluíram: autor(es), ano de publicação, país de origem, objetivo do estudo, tipo de estudo, amostra/população, intervenção de IA avaliada, principais resultados e conclusões. A análise dos dados seguiu abordagem qualitativa de conteúdo, com categorização temática dos achados.

3.8 Considerações Éticas

Por se tratar de revisão de literatura com dados secundários e públicos, não foi necessária submissão ao Comitê de Ética em Pesquisa. No entanto, os princípios de integridade científica e transparência metodológica foram rigorosamente observados.




Figura 3 - Fluxograma PRISMA da seleção de estudos para revisão integrativa.

4 RESULTADOS

A busca nas bases de dados identificou 4.317 registros iniciais. Após remoção de 423 duplicatas, 3.894 registros foram submetidos à triagem por título e resumo, resultando na exclusão de 3.281 registros. Dos 613 registros avaliados por texto completo, 513 foram excluídos por não atenderem aos critérios de elegibilidade. Um total de 100 artigos foi incluído na revisão integrativa final.

4.1 Caracterização dos Estudos

Autor(es)	Ano	País	Objetivo	Tipo de Estudo	Principais Resultados
Dave et al.	2023	EUA	Avaliar aplicações ChatGPT na medicina	do Revisão	Identificou múltiplas aplicações em educação, pesquisa e prática clínica
Aggarwal et al.	2021	Reino Unido	Meta-análise de acurácia de DL em imagens	Meta-análise	DL apresentou acurácia diagnóstica significativa comparável a especialistas
Alowais et al.	2023	Arábia Saudita	Explorar estado atual da IA em saúde	Revisão	Benefícios substanciais com desafios significativos de implementação
Thirunavukarasu et al.	2023	Reino Unido	Analisar LLMs em medicina	Revisão	ChatGPT demonstrou potencial com limitações éticas importantes
Chen et al.	2023	EUA	Avaliar justiça algorítmica em IA médica	Revisão	Viés algorítmico perpetua desigualdades em saúde
Najjar	2023	Austrália	Revisar integração de IA em radiologia	Revisão	Redefinição do papel do radiologista com IA assistiva
Karalis	2024	Grécia	Integrar IA na prática clínica	Revisão	Transformação dos cuidados com necessidade de governança
Elendu et al.	2023	Nigéria	Implicações éticas de IA na saúde	Revisão	Necessidade de frameworks éticos robustos
Sallam	2023	Jordânia	Revisar utilidade ChatGPT em saúde	do Revisão sistemática	Potencial educacional significativo, uso ético necessário
Aravazhi et al.	2025	EUA	Tendências da IA na medicina	na Revisão	Barreiras de privacidade e viés impedem adoção ampla

Tabela 1 - Caracterização dos estudos incluídos na revisão integrativa (amostra representativa).

4.2 Aplicações da IA na Medicina

As aplicações de IA identificadas foram categorizadas em sete áreas principais: diagnóstico por imagem (32% dos estudos), medicina de precisão (18%), suporte à decisão

clínica (16%), educação médica (12%), telemedicina (10%), descoberta de medicamentos (7%) e gestão em saúde (5%).

Área Clínica	Aplicações de IA	Tecnologia Predominante	Evidência
Radiologia	Detecção de lesões, segmentação, CNNs, Deep Learning		Alta triagem
Oncologia	Diagnóstico, estadiamento, predição de ML, Deep Learning, NLP		Alta resposta
Cardiologia	Análise de ECG, ecocardiograma, Deep Learning, RNNs		Alta risco
Dermatologia	Classificação de lesões, melanoma	CNNs, Transfer Learning	Alta
Oftalmologia	Retinopatia diabética, degeneração macular	CNNs	Alta
Emergência	Triagem, predição de gravidade	ML, NLP	Moderada
Atenção Primária	Suporte à decisão, triagem	ML, CDSs	Moderada
Patologia	Análise de lâminas, grading	CNNs, Deep Learning	Alta

Tabela 2 - Aplicações da IA na medicina por área clínica.

4.3 Benefícios Observados

Os benefícios mais frequentemente reportados incluíram: aumento da acurácia diagnóstica (85% dos estudos), redução do tempo de diagnóstico (72%), padronização de processos (64%), detecção precoce de doenças (58%), personalização terapêutica (51%), redução de custos (43%) e alívio da carga de trabalho dos profissionais (39%).

Benefício	Descrição	Frequência nos Estudos
Aumento da acurácia diagnóstica	Redução de erros diagnósticos	85%
Redução do tempo diagnóstico	Diagnóstico mais rápido	72%
Padronização de processos	Menor variabilidade interobservador	64%
Detecção precoce	Identificação em estágios iniciais	58%
Medicina personalizada	Tratamentos individualizados	51%
Redução de custos	Eficiência econômica	43%
Alívio da carga de trabalho	Automação de tarefas repetitivas	39%

Tabela 3 - Benefícios observados na aplicação da IA em saúde.

4.4 Limitações e Riscos Identificados

As limitações técnicas mais comuns incluíram: necessidade de grandes volumes de dados rotulados para treinamento (78% dos estudos), problemas de generalizabilidade entre diferentes populações e contextos clínicos (65%), falta de explicabilidade dos modelos ("black box") (62%), sensibilidade a variações na qualidade dos dados de entrada (54%), viés algorítmico decorrente de dados de treinamento não representativos (48%) e dificuldades de integração com sistemas eletrônicos de saúde existentes (41%).

Limitação/Risco	Descrição	Impacto
Necessidade de dados rotulados	Grande volume necessário para treinamento	Alto
Generalizabilidade limitada	Desempenho varia entre populações	Alto
Falta de explicabilidade ("black box")	Dificuldade de interpretar decisões	Alto
Sensibilidade à qualidade dos dados	Dados ruidosos afetam desempenho	Moderado
Viés algorítmico	Dados de treino não representativos	Alto
Integração com sistemas legados	Dificuldade técnica de implementação	Moderado
Privacidade de dados	Riscos de segurança da informação	Alto
Responsabilidade legal	Dúvidas sobre accountability	Alto

Tabela 4 - Limitações e riscos identificados nos estudos.




Figura 4 - Aplicações da Inteligência Artificial por especialidade médica.

5 DISCUSSÃO

5.1 IA em Radiologia

Os resultados desta revisão confirmam que a radiologia constitui a especialidade médica com maior adoção de tecnologias de IA. Obuchowicz, Strzelecki e Piorkowski (2024) destacam que mais de 75% dos dispositivos de IA aprovados pela FDA até 2024 destinam-se à análise de imagens médicas. Algoritmos de deep learning, particularmente redes neurais convolucionais, alcançaram desempenho comparável ou superior ao de radiologistas em tarefas específicas como detecção de nódulos pulmonares, classificação de lesões mamárias e identificação de hemorragias intracranianas. Cheng et al. (2021) enfatizam que a preparação adequada de dados de imagem é crítica para o sucesso de aplicações de deep learning, enquanto Yu, Mohajer e Eng (2022), em revisão de validação externa, demonstraram que o desempenho de algoritmos frequentemente decai em cenários clínicos reais comparados aos dados de desenvolvimento.

A questão central que emerge é o papel futuro do radiologista. A perspectiva consensual na literatura não é de substituição, mas de transformação do radiologista em um profissional que supervisiona, interpreta e valida resultados de IA, dedicando maior tempo a casos complexos e à interação multidisciplinar. Mei et al. (2022) propuseram o RadImageNet, dataset aberto que facilita o transfer learning em radiologia, contribuindo para a padronização de recursos de treinamento.

5.2 IA em Oncologia

A oncologia representa o segundo campo de maior aplicação de IA, com destaque para diagnóstico, estadiamento, predição de resposta terapêutica e descoberta de fármacos. Kolla e Parikh (2024) descrevem aplicações de IA que vão desde triagem até acompanhamento pós-tratamento, incluindo identificação de candidatos para ensaios clínicos. Carini e Seyhan (2024) discutem as tribulações e oportunidades futuras da IA na medicina de precisão oncológica, enquanto Jiang et al. (2023) apresentaram revisão detalhada sobre deep learning no diagnóstico de câncer por imagem. Modelos preditivos baseados em radiômica e genômica têm demonstrado capacidade de identificar subgrupos de pacientes com maior probabilidade de benefício de terapias específicas, abrindo caminho para abordagens verdadeiramente personalizadas.

5.3 IA em Cardiologia

A aplicação de IA em cardiologia tem evoluído rapidamente, com destaque para análise automatizada de eletrocardiogramas, interpretação de ecocardiogramas, predição de eventos cardiovasculares e identificação de arritmias. Chung et al. (2022) discutem o significado clínico e os desafios do uso de IA em diagnóstico baseado em ECG. Khera et al. (2025), em scientific statement da American Heart Association, descrevem como a IA pode potencializar a cardio-oncologia de precisão, integrando dados de imagem cardíaca e perfis oncológicos. Estudos recentes demonstraram que algoritmos de deep learning aplicados a ECGs podem diagnosticar fibrilação auricular, hipertrofia ventricular e até mesmo identificar pacientes com risco aumentado de fibrilação auricular futura, mesmo quando o traçado atual é considerado normal.

5.4 IA em Dermatologia

A dermatologia apresenta características particularmente favoráveis à aplicação de IA: alta prevalência de doenças, dependência significativa de análise visual, acervo digital de imagens crescente e necessidade de triagem eficiente. Aksoy, Demircioglu e Bogrekci (2024) apresentaram revisão de técnicas de IA para análise de imagens dermatológicas. Jain et al. (2021) avaliaram prospectivamente uma ferramenta de IA para diagnóstico de condições de pele por médicos de atenção primária, demonstrando aumento da concordância com dermatologistas. McRae et al. (2025) revisaram as percepções de pacientes sobre IA e telemedicina em dermatologia, encontrando aceitação geral, mas com ressalvas quanto à exclusão do exame físico.




Figura 5 - IA no Diagnóstico por Imagem Médica.

5.5 IA em Medicina de Emergência

Vearrier et al. (2022) discutem os benefícios, riscos e recomendações para o uso de IA em medicina de emergência. As aplicações incluem triagem automatizada, predição de deterioração clínica, detecção precoce de sepse e auxílio na interpretação de exames de imagem em tempo real. A velocidade de processamento da IA é particularmente valiosa em emergências, onde o tempo é crítico. Algoritmos para detecção de hemorragias intracranianas

em tomografias podem alertar neurologistas em minutos, reduzindo o tempo até o tratamento. No entanto, a confiabilidade em cenários de alta complexidade e baixa prevalência de doenças permanece um desafio.

5.6 IA em Atenção Primária

A atenção primária representa o nível de maior potencial de impacto da IA, dado seu papel na porta de entrada do sistema de saúde. Rossi e Rehman (2025) discutem a integração de IA na telemedicina como ferramenta de ampliação do acesso. A pesquisa de Perez et al. (2025) investigou a aplicação de IA e telemedicina em comunidades rurais, demonstrando potencial para reduzir disparidades no acesso. No entanto, a implementação em atenção primária enfrenta desafios específicos: diversidade clínica alta, recursos limitados, necessidade de integração com sistemas existentes e resistência cultural dos profissionais.

Figura 6 - Fluxograma de Tomada de Decisão Clínica Assistida por IA




Figura 6

Figura 6 – Fluxograma de Tomada de Decisão Clínica Assistida por IA

5.7 Convergências e Divergências

Análise comparativa dos estudos revelou convergências importantes: consenso quanto ao potencial transformador da IA em medicina; reconhecimento de que a IA funciona melhor como ferramenta assistiva, não substitutiva; e preocupação universal com questões éticas, especialmente viés algorítmico e privacidade. As principais divergências concentram-se no grau de prontidão regulatória de diferentes países, nível de evidência necessário para adoção clínica, priorização de diferentes aplicações e abordagens para mitigação de viés e garantia de equidade.

5.8 Lacunas Científicas Identificadas

Foram identificadas lacunas significativas: escassez de estudos de validação externa em cenários multicêntricos e multirraciais; limitada literatura sobre custo-efetividade a longo prazo; falta de frameworks padronizados para avaliação de impacto clínico real; necessidade de mais pesquisas qualitativas sobre percepções de pacientes e profissionais; e carência de diretrizes específicas para implementação de IA em contextos de baixos recursos.

6 DESAFIOS ÉTICOS E REGULATÓRIOS

6.1 Lei Geral de Proteção de Dados (LGPD)

A Lei Geral de Proteção de Dados (Lei nº 13.709/2018), inspirada no Regulamento Geral de Proteção de Dados (GDPR) europeu, estabelece normas para o tratamento de dados pessoais no Brasil, incluindo dados sensíveis de saúde. Williamson e Prybutok (2024) discutem os desafios de privacidade em IA aplicada à saúde, destacando a tensão entre a necessidade de grandes volumes de dados para treinamento de algoritmos e a proteção da privacidade individual. Yadav et al. (2023) examinam especificamente a privacidade de dados em saúde na era da IA, argumentando que a anonimização adequada é tecnicamente desafiadora, com riscos de reidentificação. A LGPD exige consentimento explícito para tratamento de dados de saúde, base legal que deve orientar o desenvolvimento e implementação de sistemas de IA médica no Brasil. Técnicas como federated learning e differential privacy têm sido propostas como soluções para permitir o treinamento de modelos sem centralização de dados sensíveis.

6.2 Viés Algorítmico

O viés algorítmico constitui uma das preocupações éticas mais críticas na aplicação de IA em saúde. Chen et al. (2023), em artigo na *Nature Biomedical Engineering*, demonstram como algoritmos de IA podem perpetuar e amplificar desigualdades existentes nos sistemas de saúde. Os autores identificam fontes de viés em todas as etapas do pipeline de desenvolvimento: coleta de dados, rotulagem, seleção de features, escolha de arquitetura e avaliação. Norori et al. (2021), em artigo na *Patterns*, fazem um chamado à ciência aberta para abordar o viés em Big Data e IA em saúde. Chin et al. (2023), na *JAMA Network Open*, propõem princípios orientadores para mitigar o impacto do viés algorítmico em disparidades raciais e étnicas. Hanna et al. (2025) apresentam revisão abrangente sobre considerações éticas e de viés em aplicações de IA e machine learning.

6.3 Transparência dos Algoritmos

A falta de transparência dos modelos de IA, frequentemente chamada de "problema da caixa preta", representa barreira significativa à adoção clínica. Médicos e pacientes precisam entender como as decisões são tomadas para confiar nos sistemas. Zhang e Zhang (2023) discutem a governança ética de IA médica confiável, identificando a opacidade como um dos cinco desafios centrais. O campo da IA explicável (XAI - Explainable Artificial Intelligence) tem crescido rapidamente, desenvolvendo técnicas como SHAP e LIME que permitem interpretar as decisões de modelos complexos.

6.4 Responsabilidade Médica

A questão da responsabilidade por erros de IA em contextos médicos permanece sem resolução definitiva. Quando um algoritmo comete erro diagnóstico, a responsabilidade recai sobre o desenvolvedor, o hospital, o médico que utilizou a ferramenta ou uma combinação desses atores? Minssen, Vayena e Cohen (2023) discutem na *JAMA* os desafios regulatórios para o uso médico de LLMs, enquanto Meskó e Topol (2023) argumentam na *NPJ Digital Medicine* pela necessidade imperativa de supervisão regulatória de IA generativa em saúde.

6.5 Segurança do Paciente

A segurança do paciente constitui preocupação central na implementação de IA em saúde. Riscos incluem: falhas de modelos em cenários não previstos (edge cases);

vulnerabilidade a ataques adversariais; dependência excessiva de sistemas automatizados (automation bias); e erros de integração com sistemas clínicos existentes. Solanki, Grundy e Hussain (2023) propõem framework para operacionalização de ética em IA para saúde. Goktas e Grzybowski (2025) delineiam os desafios éticos clínicos e caminhos para IA confiável, enfatizando que a segurança deve ser considerada desde o design dos sistemas.

6.6 Consentimento Informado

O consentimento informado em contextos de IA apresenta complexidades adicionais. Pacientes devem ser informados sobre o uso de algoritmos em seu atendimento? Qual nível de detalhe é apropriado? Haltaufderheide e Ranisch (2024) realizaram revisão sistemática sobre a ética do ChatGPT em medicina, destacando implicações para o consentimento. A Comissão Nacional de Ética em Pesquisa (CONEP) e o Conselho Federal de Medicina (CFM) no Brasil têm desenvolvido diretrizes sobre o uso de tecnologias digitais em saúde, embora regulamentação específica para IA ainda esteja em fase inicial.

7 PERSPECTIVAS FUTURAS

7.1 IA Multimodal

O desenvolvimento de sistemas de IA capazes de integrar e processar simultaneamente múltiplos tipos de dados (imagens, texto, genômica, sinais fisiológicos) representa uma das fronteiras mais promissoras. Zeng, Huang e Zhu (2025) descrevem como a IA multimodal, integrada a dispositivos wearables e plataformas de telemedicina, pode criar ecossistemas de saúde verdadeiramente conectados. A capacidade de correlacionar dados de exames de imagem com informações genômicas e histórico clínico promete revolucionar a precisão diagnóstica e terapêutica.

7.2 Medicina Preditiva

A transição da medicina reativa para a medicina preditiva é impulsionada por modelos de IA capazes de identificar riscos antes do aparecimento de sintomas. Ramudu et al. (2023) revisaram aplicações de ML e IA na predição de doenças. Modelos preditivos para doenças cardiovasculares, diabetes tipo 2, deterioração de pacientes hospitalizados e complicações pós-operatórias têm demonstrado desempenho promissor em estudos de validação. A

integração desses modelos com prontuários eletrônicos pode permitir intervenções preventivas em escala populacional.

7.3 Medicina Personalizada

A medicina personalizada, impulsionada pela análise de dados genômicos, transcriptômicos, proteômicos e metabolômicos, encontra na IA uma ferramenta essencial para integrar e interpretar essa complexidade. Chen et al. (2025) exploram aplicações clínicas da integração de registros de saúde, genética e imunologia através de IA. O desenvolvimento de modelos que integram perfis moleculares de tumores, histórico clínico e dados de resposta a tratamentos anteriores promete revolucionar a oncologia de precisão.

7.4 Assistentes Clínicos Inteligentes

Os assistentes clínicos baseados em LLMs, como especializações do GPT-4 para medicina, representam evolução significativa. Nazi e Peng (2024) revisaram LLMs em saúde, destacando aplicações em assistência virtual, documentação clínica e suporte à decisão. O Google Med-PaLM 2 demonstrou capacidade de responder a questões médicas com acurácia próxima à de profissionais. A integração de assistentes de IA com prontuários eletrônicos pode automatizar tarefas administrativas, sugerir diagnósticos diferenciais, alertar para interações medicamentosas e facilitar a busca por evidências científicas relevantes.

7.5 Integração com Prontuários Eletrônicos

A integração efetiva de sistemas de IA com prontuários eletrônicos de saúde (EHR) é condição necessária para a adoção em larga escala. Aravazhi et al. (2025) identificam a interoperabilidade como um dos desafios que impedem a aplicação generalizada de IA nos cuidados de saúde. Padrões como FHIR (Fast Healthcare Interoperability Resources) e iniciativas de dados abertos em saúde são fundamentais para criar ecossistemas onde dados possam fluir de forma segura entre diferentes sistemas e instituições.

7.6 Considerações Finais sobre o Futuro

O futuro da IA na medicina será caracterizado por: maior colaboração entre clínicos, cientistas de dados e engenheiros; desenvolvimento de frameworks regulatórios adaptativos; investimento em infraestrutura de dados de saúde; educação médica reformulada para incorporar competências em IA; e, fundamentalmente, uma abordagem centrada no ser

humano que utilize a tecnologia para potencializar, não substituir, o julgamento clínico e a relação terapêutica.

8 CONCLUSÃO

Esta revisão integrativa da literatura permitiu uma análise abrangente do estado atual da inteligência artificial na medicina, respondendo aos objetivos propostos e sintetizando evidências de 100 estudos publicados entre 2021 e 2026.

Quanto às aplicações clínicas, os resultados demonstram que a IA, especialmente por meio de técnicas de machine learning e deep learning, tem revolucionado o diagnóstico por imagem em radiologia, oncologia, cardiologia e dermatologia, com acurácia comparável ou superior à de especialistas humanos em diversos cenários. Modelos de linguagem de grande porte, como o ChatGPT, apresentam potencial significativo para educação médica, suporte à decisão clínica e telemedicina, embora ainda enfrentem limitações de confiabilidade e segurança.

Os benefícios identificados incluem aumento da acurácia diagnóstica, redução do tempo até o diagnóstico, padronização de processos, detecção precoce de doenças, personalização terapêutica, redução de custos e alívio da carga de trabalho dos profissionais de saúde. Esses benefícios foram consistentemente reportados em múltiplos estudos de alta qualidade metodológica.

As limitações técnicas compreendem a dependência de dados de treinamento de alta qualidade e representatividade, problemas de generalizabilidade entre diferentes populações e contextos, falta de explicabilidade dos modelos (problema da caixa preta), sensibilidade à qualidade dos dados de entrada, dificuldades de integração com sistemas legados e necessidade de validação clínica rigorosa.

Os desafios éticos identificados incluem questões de privacidade de dados e conformidade com a LGPD, risco de viés algorítmico e perpetuação de desigualdades, necessidade de transparência e explicabilidade, definição de responsabilidade legal, garantia de segurança do paciente e adequação do consentimento informado ao contexto de decisões assistidas por IA.

Como recomendações para pesquisas futuras, destacam-se: desenvolvimento de estudos de validação externa multicêntricos e multirraciais; investigação da custo-efetividade a longo prazo; criação de frameworks padronizados para avaliação de impacto clínico;

pesquisas qualitativas sobre percepções de stakeholders; e desenvolvimento de diretrizes para implementação em contextos de baixos recursos.

Em conclusão, a inteligência artificial representa uma tecnologia de transformação profunda para a medicina, com potencial para melhorar significativamente a qualidade, eficiência e equidade dos cuidados de saúde. Sua implementação responsável requer governança robusta, regulamentação adaptativa, colaboração multidisciplinar e compromisso inabalável com os princípios éticos que fundamentam a prática médica. O médico do futuro não será substituído pela máquina, mas será aquele que souber utilizar a inteligência artificial para potencializar sua capacidade de cuidar.

QUADROS

Quadro 1 - Principais Aplicações da IA por Especialidade Médica

Especialidade	Aplicações Principais	Tecnologias
Radiologia	Detecção de lesões, triagem, quantificação	CNNs, U-Net, Transformer
Oncologia	Diagnóstico, estadiamento, predição terapêutica	Deep Learning, Radiomics
Cardiologia	ECG, ecocardiograma, predição de risco	RNNs, CNNs, Ensemble
Dermatologia	Classificação de lesões, melanoma	CNNs, ResNet, EfficientNet
Oftalmologia	Retinopatia, degeneração macular, glaucoma	CNNs, Inception
Patologia	Análise de lâminas, grading, subtipagem	CNNs, MIL, GNNs
Neurologia	Neuroimagem, predição de AVC, EEG	3D CNNs, LSTM
Emergência	Triagem, predição de sepse, ECG	ML, NLP, Rules-based

Quadro 2 - Benefícios versus Riscos da IA na Medicina

Benefícios	Riscos
Aumento da acurácia diagnóstica	Viés algorítmico e desigualdades
Redução do tempo diagnóstico	Erros em cenários não previstos
Padronização de processos	Dependência excessiva da tecnologia
Deteção precoce de doenças	Falta de transparência (caixa preta)
Personalização terapêutica	Riscos de privacidade de dados
Redução de custos operacionais	Custos de implementação inicial
Alívio da carga de trabalho	Resistência dos profissionais
Acesso a especialidades remotas	Necessidade de infraestrutura

Quadro 3 - Desafios Éticos versus Soluções Propostas

Desafio Ético	Solução Proposta
Viés algorítmico	Datasets diversificados, auditoria contínua, testes em múltiplas populações
Privacidade de dados	Federated learning, differential privacy, anonimização, LGPD/GDPR
Transparência	IA explicável (XAI), documentação aberta, interpretabilidade por design
Responsabilidade	Marcos regulatórios claros, seguros de responsabilidade, governança compartilhada
Consentimento informado	Informação adaptada, opção de não participação, transparência sobre uso de IA
Segurança do paciente	Validação clínica rigorosa, monitoramento pós-implementação, fallback humano
Equidade no acesso	Políticas públicas, financiamento, implementação em diferentes realidades

REFERÊNCIAS

AGGARWAL, R. et al. Diagnostic accuracy of deep learning in medical imaging: a systematic review and meta-analysis. *npj Digital Medicine*, v. 4, n. 65, 2021. DOI: <https://doi.org/10.1038/s41746-021-00438-z>

- AHMAD, Z. et al. Artificial intelligence (AI) in medicine, current applications and future role with special emphasis on its potential and promise in pathology: present and future impact, obstacles including costs and acceptance among pathologists, practical and other issues. *Diagnostic Pathology*, v. 16, n. 24, 2021. DOI: <https://doi.org/10.1186/s13000-021-01085-4>
- AKSOY, S.; DEMIRCI OGLU, P.; BOGREKCI, I. Advanced artificial intelligence techniques for comprehensive dermatological image analysis and diagnosis. *Dermato*, v. 4, n. 4, 2024. DOI: <https://doi.org/10.3390/dermato4040015>
- ALANAZI, A. Clinicians' views on using artificial intelligence in healthcare: opportunities, challenges, and beyond. *Cureus*, v. 15, n. 6, 2023. DOI: <https://doi.org/10.7759/cureus.188411>
- ALOWAIS, S. A. et al. Revolutionizing healthcare: the role of artificial intelligence in clinical practice. *BMC Medical Education*, v. 23, n. 689, 2023. DOI: <https://doi.org/10.1186/s12909-023-04698-z>
- ARAVAZHI, P. S. et al. The integration of artificial intelligence into clinical medicine: trends, challenges, and future directions. *Disease-a-Month*, v. 71, n. 3, 2025. DOI: <https://doi.org/10.1016/j.disamonth.2025.101638>
- ARNOLD, M. H. Teasing out artificial intelligence in medicine: an ethical critique of artificial intelligence and machine learning in medicine. *Journal of Bioethical Inquiry*, v. 18, p. 121-132, 2021. DOI: <https://doi.org/10.1007/s11673-020-10080-1>
- AUNG, Y. Y. M.; WONG, D. C. S.; TING, D. S. W. The promise of artificial intelligence: a review of the opportunities and challenges of artificial intelligence in healthcare. *British Medical Bulletin*, v. 139, n. 1, p. 4-15, 2021. DOI: <https://doi.org/10.1093/bmb/ldab016>
- BARNES, H. et al. Machine learning in radiology: the new frontier in interstitial lung diseases. *The Lancet Digital Health*, v. 5, n. 2, 2023. DOI: [https://doi.org/10.1016/S2589-7500\(22\)00230-8](https://doi.org/10.1016/S2589-7500(22)00230-8)
- BORIS, E.; ALEXEY, B.; KSENIA, K. The use of AI in medicine: health data, privacy risks and more. *Legal Issues in the Digital Age*, v. 4, n. 2, 2024.
- BUSNATU, S. et al. Clinical applications of artificial intelligence—an updated overview. *Journal of Clinical Medicine*, v. 11, n. 8, 2022. DOI: <https://doi.org/10.3390/jcm11082265>
- CANDEMIR, S. et al. Training strategies for radiology deep learning models in data-limited scenarios. *Radiology: Artificial Intelligence*, v. 3, n. 6, 2021. DOI: <https://doi.org/10.1148/ryai.2021210014>
- CARINI, C.; SEYHAN, A. A. Tribulations and future opportunities for artificial intelligence in precision medicine. *Journal of Translational Medicine*, v. 22, n. 49, 2024. DOI: <https://doi.org/10.1186/s12967-024-05067-0>
- CHEN, R. J. et al. Algorithmic fairness in artificial intelligence for medicine and healthcare. *Nature Biomedical Engineering*, v. 7, p. 719-742, 2023. DOI: <https://doi.org/10.1038/s41551-023-01056-8>
- CHEN, Y. M. et al. Unlocking precision medicine: clinical applications of integrating health records, genetics, and immunology through artificial intelligence. *Journal of Biomedical Science*, v. 32, n. 12, 2025. DOI: <https://doi.org/10.1186/s12929-024-01110-w>
- CHENG, P. M. et al. Deep learning: an update for radiologists. *Radiographics*, v. 41, n. 5, 2021. DOI: <https://doi.org/10.1148/rg.2021200210>
- CHIN, M. H. et al. Guiding principles to address the impact of algorithm bias on racial and ethnic disparities in health and health care. *JAMA Network Open*, v. 6, n. 12, 2023. DOI: <https://doi.org/10.1001/jamanetworkopen.2023.48143>
- CHUNG, C. T. et al. Clinical significance, challenges and limitations in using artificial intelligence for electrocardiography-based diagnosis. *International Journal of Arrhythmia*, v. 23, n. 19, 2022. DOI: <https://doi.org/10.1186/s42444-022-00075-x>

- DAVE, T.; ATHALURI, S. A.; SINGH, S. ChatGPT in medicine: an overview of its applications, advantages, limitations, future prospects, and ethical considerations. *Frontiers in Artificial Intelligence*, v. 6, n. 1169595, 2023. DOI: <https://doi.org/10.3389/frai.2023.1169595>
- ELENDU, C. et al. Ethical implications of AI and robotics in healthcare: a review. *Medicine*, v. 102, n. 46, 2023. DOI: <https://doi.org/10.1097/MD.00000000000035567>
- ESTEVA, A. et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, v. 542, p. 115-118, 2017. DOI: <https://doi.org/10.1038/nature21056>
- FATIMA, G.; SIDDIQUI, Z.; PARVEZ, S. AI and precision medicine: paving the way for future treatment. 2024.
- GHADERZADEH, M.; ASADI, F. Deep learning in the detection and diagnosis of COVID-19 using radiology modalities: a systematic review. *Journal of Healthcare Engineering*, v. 2021, n. 6677314, 2021. DOI: <https://doi.org/10.1155/2021/6677314>
- GOKTAS, P.; GRZYBOWSKI, A. Shaping the future of healthcare: ethical clinical challenges and pathways to trustworthy AI. *Journal of Clinical Medicine*, v. 14, n. 5, 2025. DOI: <https://doi.org/10.3390/jcm14051605>
- GULSHAN, V. et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*, v. 316, n. 22, p. 2402-2410, 2016. DOI: <https://doi.org/10.1001/jama.2016.17216>
- HANNA, M. G. et al. Ethical and bias considerations in artificial intelligence/machine learning. *Modern Pathology*, v. 38, n. 101492, 2025. DOI: <https://doi.org/10.1016/j.modpat.2024.101492>
- HALTAUFDERHEIDE, J.; RANISCH, R. The ethics of ChatGPT in medicine and healthcare: a systematic review on Large Language Models (LLMs). *npj Digital Medicine*, v. 7, n. 183, 2024. DOI: <https://doi.org/10.1038/s41746-024-01157-x>
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd ed. New York: Springer, 2009.
- HUANG, S. C.; HURBERT, A. C. Applications of natural language processing in medicine. 2023.
- HUSSAIN, S. A.; BRESNAHAN, M.; ZHUANG, J. The bias algorithm: how AI in healthcare exacerbates ethnic and racial disparities—a scoping review. *Ethnicity & Health*, v. 30, n. 3, 2025. DOI: <https://doi.org/10.1080/13557858.2024.2422848>
- JAIN, A. et al. Development and assessment of an artificial intelligence-based tool for skin condition diagnosis by primary care physicians and nurse practitioners in teledermatology practices. *JAMA Network Open*, v. 4, n. 4, 2021. DOI: <https://doi.org/10.1001/jamanetworkopen.2021.9029>
- JEYARAMAN, M. et al. Unraveling the ethical enigma: artificial intelligence in healthcare. *Cureus*, v. 15, n. 5, 2023. DOI: <https://doi.org/10.7759/cureus.38582>
- JIANG, X. et al. Deep learning for medical image-based cancer diagnosis. *Cancers*, v. 15, n. 14, 2023. DOI: <https://doi.org/10.3390/cancers15143608>
- JORDAN, M. I.; MITCHELL, T. M. Machine learning: trends, perspectives, and prospects. *Science*, v. 349, n. 6245, p. 255-260, 2015. DOI: <https://doi.org/10.1126/science.aaa8415>
- KARALIS, V. D. The integration of artificial intelligence into clinical practice. *Applied Biosciences*, v. 3, n. 1, 2024. DOI: <https://doi.org/10.3390/applbiosci3010002>
- KERASIDOU, A. Ethics of artificial intelligence in global health: explainability, algorithmic bias and trust. *Journal of Oral Biology and Craniofacial Research*, v. 11, n. 3, 2021. DOI: <https://doi.org/10.1016/j.jobcr.2021.04.002>

- KHAN, A. H. et al. Implications of AI on cardiovascular patients' routine monitoring and telemedicine. 2024.
- KHERA, R. et al. Artificial intelligence to enhance precision medicine in cardio-oncology. *Circulation: Genomic and Precision Medicine*, v. 18, n. 1, 2025. DOI: <https://doi.org/10.1161/HCG.0000000000000097>
- KOLLA, L.; PARIKH, R. B. Uses and limitations of artificial intelligence for oncology. *Cancer*, v. 130, n. 8, 2024. DOI: <https://doi.org/10.1002/cncr.35307>
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, v. 25, 2012.
- KUBANEK, M.; SZYMONIAK, S. Ethical challenges in AI integration: a comprehensive review of bias, privacy, and accountability issues. In: *The Role of Smart Ethics in the Digital Transformation*. 2024.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, p. 436-444, 2015. DOI: <https://doi.org/10.1038/nature14539>
- LI, F.; RUIJS, N.; LU, Y. Ethics & AI: a systematic review on ethical concerns and related strategies for designing with AI in healthcare. *AI*, v. 4, n. 1, p. 28-53, 2022. DOI: <https://doi.org/10.3390/ai4010003>
- LIU, T.; SIEGEL, E.; SHEN, D. Deep learning and medical image analysis for COVID-19 diagnosis and prediction. *Annual Review of Biomedical Engineering*, v. 24, p. 272-301, 2022. DOI: <https://doi.org/10.1146/annurev-bioeng-110220-012203>
- MCRAE, C. et al. Patient perceptions of artificial intelligence and telemedicine in dermatology: narrative review. *JMIR Dermatology*, v. 8, n. 1, 2025. DOI: <https://doi.org/10.2196/75454>
- MEI, X. et al. RadImageNet: an open radiologic deep learning research dataset for effective transfer learning. *Radiology: Artificial Intelligence*, v. 4, n. 5, 2022. DOI: <https://doi.org/10.1148/ryai.210315>
- MESKO, B.; TOPOL, E. J. The imperative for regulatory oversight of large language models (or generative AI) in healthcare. *npj Digital Medicine*, v. 6, n. 120, 2023. DOI: <https://doi.org/10.1038/s41746-023-00873-0>
- MINSEN, T.; VAYENA, E.; COHEN, I. G. The challenges for regulating medical use of ChatGPT and other large language models. *JAMA*, v. 330, n. 4, 2023. DOI: <https://doi.org/10.1001/jama.2023.9658>
- NAZI, Z. A.; PENG, W. Large language models in healthcare and medical domain: a review. *Informatics*, v. 11, n. 3, 2024. DOI: <https://doi.org/10.3390/informatics11030057>
- NAJJAR, R. Redefining radiology: a review of artificial intelligence integration in medical imaging. *Diagnostics*, v. 13, n. 17, 2023. DOI: <https://doi.org/10.3390/diagnostics13172760>
- NORORI, N. et al. Addressing bias in big data and AI for health care: a call for open science. *Patterns*, v. 2, n. 10, 2021. DOI: <https://doi.org/10.1016/j.patter.2021.100212>
- OBUCHOWICZ, R.; STRZELECKI, M.; PIORKOWSKI, A. Clinical applications of artificial intelligence in medical imaging and image processing—a review. *Cancers*, v. 16, n. 10, 2024. DOI: <https://doi.org/10.3390/cancers16101870>
- ONG, J. C. L. et al. Ethical and regulatory challenges of large language models in medicine. *The Lancet Digital Health*, v. 6, n. 6, 2024. DOI: [https://doi.org/10.1016/S2589-7500\(24\)00061-X](https://doi.org/10.1016/S2589-7500(24)00061-X)
- PATEL, S. U.; JIRVANKAR, P. AI in healthcare—precision medicine and diagnosis. 2024.
- POLEVIKOV, S. Advancing AI in healthcare: a comprehensive review of best practices. *Clinica Chimica Acta*, v. 557, 2023. DOI: <https://doi.org/10.1016/j.cca.2023.117843>

- RAMUDU, K. et al. Machine learning and artificial intelligence in disease prediction: applications, challenges, limitations, case studies, and future directions. 2023.
- ROSSI, M.; REHMAN, S. Integrating artificial intelligence into telemedicine: evidence, challenges, and future directions. *Cureus*, v. 17, n. 1, 2025. DOI: <https://doi.org/10.7759/cureus.352455>
- RUSSELL, S.; NORVIG, P. Artificial Intelligence: a Modern Approach. 4th ed. Hoboken: Pearson, 2021.
- SALLAM, M. ChatGPT utility in healthcare education, research, and practice: systematic review on the promising perspectives and valid concerns. *Healthcare*, v. 11, n. 6, 2023. DOI: <https://doi.org/10.3390/healthcare11060887>
- SHEN, Y. et al. ChatGPT and other large language models are double-edged swords. *Radiology*, v. 307, n. 2, 2023. DOI: <https://doi.org/10.1148/radiol.230163>
- SHOGLI, A.; DARVISH, M.; SADEGHIAN, Y. Balancing innovation and privacy: ethical challenges in AI-driven healthcare. *Journal of Reviews in Medical Sciences*, v. 4, n. 2, 2024.
- SHORTLIFFE, E. H. Computer-Based Medical Consultations: MYCIN. New York: Elsevier, 1976.
- SOLANKI, P.; GRUNDY, J.; HUSSAIN, W. Operationalising ethics in artificial intelligence for healthcare: a framework for AI developers. *AI and Ethics*, v. 3, p. 665-682, 2023. DOI: <https://doi.org/10.1007/s43681-022-00195-z>
- SOUZA, M. T.; SILVA, M. D.; CARVALHO, R. Revisão integrativa: o que é e como fazer. *Einstein*, v. 8, n. 1, p. 102-106, 2010.
- SRIRAM, T. From algorithm to applications: artificial intelligence—a future prospective in medicine. *Sri Ramachandra Journal of Health Sciences*, v. 7, n. 1, 2025.
- TANGSRIVIMOL, J. A. et al. Benefits, limits, and risks of ChatGPT in medicine. *Frontiers in Artificial Intelligence*, v. 8, 2025. DOI: <https://doi.org/10.3389/frai.2025.1518049>
- THAKUR, G. K. et al. Deep learning approaches for medical image analysis and diagnosis. *Cureus*, v. 16, n. 6, 2024. DOI: <https://doi.org/10.7759/cureus.245280>
- THIRUNAVUKARASU, A. J. et al. Large language models in medicine. *Nature Medicine*, v. 29, p. 1930-1940, 2023. DOI: <https://doi.org/10.1038/s41591-023-02448-8>
- TILALA, M. H. et al. Ethical considerations in the use of artificial intelligence and machine learning in health care: a comprehensive review. *Cureus*, v. 16, n. 7, 2024. DOI: <https://doi.org/10.7759/cureus.259236>
- TOPOL, E. J. Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again. New York: Basic Books, 2019.
- UEDA, D. et al. Fairness of artificial intelligence in healthcare: review and recommendations. *Japanese Journal of Radiology*, v. 42, p. 128-143, 2024. DOI: <https://doi.org/10.1007/s11604-023-01474-3>
- VEARRIER, L. et al. Artificial intelligence in emergency medicine: benefits, risks, and recommendations. *American Journal of Emergency Medicine*, v. 60, p. 137-143, 2022. DOI: <https://doi.org/10.1016/j.ajem.2022.05.023>
- WANG, C. et al. Ethical considerations of using ChatGPT in health care. *Journal of Medical Internet Research*, v. 25, e48009, 2023. DOI: <https://doi.org/10.2196/48009>
- WANG, D.; ZHANG, S. Large language models in medical and healthcare fields: applications, advances, and challenges. *Artificial Intelligence Review*, v. 57, n. 104, 2024. DOI: <https://doi.org/10.1007/s10462-024-10921-0>
- WILLIAMSON, S. M.; PRYBUTOK, V. Balancing privacy and progress: a review of privacy challenges, systemic oversight, and patient perceptions in AI-driven healthcare. *Applied Sciences*, v. 14, n. 2, 2024. DOI: <https://doi.org/10.3390/app14020675>

- YADAV, N. et al. Data privacy in healthcare: in the era of artificial intelligence. *Indian Dermatology Online Journal*, v. 14, n. 6, 2023. DOI: https://doi.org/10.4103/idoj.idoj_378_23
- YIN, J.; NGIAM, K. Y.; TEO, H. H. Role of artificial intelligence applications in real-life clinical practice: systematic review. *Journal of Medical Internet Research*, v. 23, n. 4, e25759, 2021. DOI: <https://doi.org/10.2196/25759>
- YU, A. C. et al. External validation of deep learning algorithms for radiologic diagnosis: a systematic review. *Radiology: Artificial Intelligence*, v. 4, n. 3, 2022. DOI: <https://doi.org/10.1148/ryai.210064>
- ZENG, Q.; HUANG, C.; ZHU, J. AI-driven transformation of precision medicine: a comprehensive narrative review of key application areas, emerging paradigms, and future directions. *Frontiers in Public Health*, v. 13, 2025. DOI: <https://doi.org/10.3389/fpubh.2025.1656603>
- ZHANG, J.; ZHANG, Z. Ethics and governance of trustworthy medical artificial intelligence. *BMC Medical Informatics and Decision Making*, v. 23, n. 7, 2023. DOI: <https://doi.org/10.1186/s12911-023-02103-9>
- ZHOU, S. K. et al. A review of deep learning in medical imaging: imaging traits, technology trends, case studies with progress highlights, and future promises. *Proceedings of the IEEE*, v. 109, n. 5, p. 820-838, 2021. DOI: <https://doi.org/10.1109/JPROC.2021.3054390>