

O PAPEL DA INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO PRECOCE DE DOENÇAS: DA ANÁLISE DE IMAGEM À TRIAGEM CLÍNICA PREDITIVA

THE ROLE OF ARTIFICIAL INTELLIGENCE IN EARLY DISEASE DIAGNOSIS:
FROM IMAGE ANALYSIS TO PREDICTIVE CLINICAL SCREENING

Ciências da Saúde • 19/05/2026

REGISTRO DOI: [10.70773/revistatopicos/779073411](https://doi.org/10.70773/revistatopicos/779073411)

Mateus Figueredo da Silva¹

Bárbara Katherine Ataide Barros Rodrigues²

Eduardo Gabriel Monteiro de Oliveira Lima³

Silvânia Pinto Gomes Pereira⁴

Paula Giovanna Severino Colem Timo⁵

Ricardo Oliveira⁶

Amariles Monteiro Cabral Procopio⁷

Francisca Josyane Maciel da Penha⁸

Ezequiel Siqueira Barbosa⁹

Douglas Moura Araujo¹⁰

RESUMO

O avanço acelerado da inteligência artificial (IA) tem produzido impacto substancial na medicina diagnóstica, especialmente no que se refere à detecção precoce de doenças. O presente estudo tem como objetivo analisar, por meio de revisão integrativa da literatura científica, as principais aplicações de IA no diagnóstico precoce, abrangendo o processamento de exames de imagem, a interpretação de análises laboratoriais e os algoritmos de triagem clínica preditiva em prontuários eletrônicos. A metodologia adotada compreendeu a busca sistemática nas bases de dados PubMed e SciELO, com descritores controlados em português e inglês, aplicando-se critérios rigorosos de inclusão e exclusão para garantir a relevância e a qualidade dos estudos selecionados. Os resultados demonstram que modelos de aprendizado profundo (*deep learning*) e radiômica apresentam acurácia diagnóstica comparável ou superior à de especialistas humanos em áreas como oncologia, cardiologia e pneumologia. Os algoritmos de predição de risco baseados em prontuários eletrônicos mostraram-se eficazes na identificação antecipada de condições crônicas, como diabetes e insuficiência cardíaca. Conclui-se que a integração da IA ao fluxo diagnóstico representa avanço promissor, capaz de reduzir custos, ampliar o acesso ao diagnóstico de qualidade e melhorar a sobrevivência de pacientes, embora desafios éticos, regulatórios e de interoperabilidade ainda demandem atenção da comunidade científica e dos formuladores de políticas de saúde.

Palavras-chave: Inteligência artificial; Diagnóstico precoce; Aprendizado profundo; Exames de imagem; Triagem clínica.

ABSTRACT

The rapid advancement of artificial intelligence (AI) has produced substantial impact on diagnostic medicine, particularly regarding

early disease detection. This study aims to analyze, through an integrative review of the scientific literature, the main applications of AI in early diagnosis, encompassing medical imaging processing, laboratory analysis interpretation, and predictive clinical screening algorithms in electronic health records. The methodology adopted a systematic search of PubMed and SciELO databases, using controlled descriptors in Portuguese and English, with rigorous inclusion and exclusion criteria to ensure the relevance and quality of selected studies. Results demonstrate that deep learning models and radiomics present diagnostic accuracy comparable to or superior to human specialists in fields such as oncology, cardiology, and pulmonology. Risk prediction algorithms based on electronic health records proved effective in the early identification of chronic conditions, such as diabetes and heart failure. It is concluded that integrating AI into the diagnostic workflow represents a promising advance capable of reducing costs, expanding access to quality diagnosis, and improving patient survival, although ethical, regulatory, and interoperability challenges still require attention from the scientific community and health policy makers.

Keywords: Artificial intelligence; Early diagnosis; Deep learning; Medical imaging; Clinical screening.

1. INTRODUÇÃO

A transição da medicina analógica para a medicina de precisão digital constitui um dos fenômenos mais relevantes do século XXI. Nesse contexto, a inteligência artificial emerge como uma das tecnologias de maior impacto para a transformação dos sistemas de saúde globais, especialmente no que concerne à capacidade de processar grandes volumes de dados clínicos de forma rápida, sistemática e com elevada acurácia (Topol, 2019). A crescente

disponibilidade de dados estruturados e não estruturados provenientes de prontuários eletrônicos, exames laboratoriais, registros genômicos e imagens médicas criou as condições necessárias para o desenvolvimento de sistemas computacionais capazes de auxiliar ou, em determinados cenários, substituir o julgamento diagnóstico humano em domínios específicos.

No cenário atual, as limitações inerentes aos sistemas tradicionais de diagnóstico tornam-se cada vez mais evidentes. O diagnóstico tardio de doenças oncológicas, cardiovasculares, neurológicas e infecciosas permanece como um dos principais determinantes de morbidade e mortalidade evitáveis em todo o mundo. Segundo a Organização Mundial da Saúde (2022), aproximadamente 70% das mortes por câncer ocorrem em países de baixa e média renda, onde o acesso a especialistas e equipamentos de imagem de alta resolução é frequentemente restrito. A detecção precoce, quando viabilizada, eleva substancialmente as taxas de sobrevivência e reduz os custos associados ao tratamento em estágios avançados da doença (Shen et al., 2019).

A inteligência artificial, em suas modalidades de aprendizado de máquina (machine learning) e aprendizado profundo (deep learning), demonstra capacidade singular de identificar padrões complexos em dados clínicos que escapam à percepção humana convencional. Modelos treinados em grandes conjuntos de dados de imagens médicas radiografias, tomografias computadorizadas, ressonâncias magnéticas e histopatológicas têm apresentado resultados que rivalizam com ou superam o desempenho de radiologistas experientes em tarefas específicas de detecção de lesões (Rajpurkar et al., 2017). Da mesma forma, algoritmos de predição de risco aplicados a prontuários eletrônicos têm

demonstrado utilidade na triagem de pacientes com risco aumentado de desenvolver condições crônicas, possibilitando intervenções preventivas oportunas.

Todavia, apesar do expressivo avanço técnico-científico observado na última década, a incorporação sistemática da IA nos fluxos diagnósticos ainda enfrenta desafios consideráveis. Questões relacionadas à explicabilidade dos modelos, à privacidade dos dados, à validação clínica em populações diversas e à regulamentação dos dispositivos baseados em IA representam obstáculos que necessitam de análise crítica e abordagem multidisciplinar (Obermeyer; Emanuel, 2016). A literatura científica, embora volumosa, ainda carece de sínteses abrangentes que articulem os domínios de imagem, análise laboratorial e triagem clínica de maneira integrada.

Diante desse panorama, o presente estudo tem como objetivo analisar, por meio de revisão integrativa da literatura, as principais aplicações da inteligência artificial no diagnóstico precoce de doenças, contemplando três eixos temáticos: (a) processamento e interpretação de exames de imagem médica; (b) análise de biomarcadores laboratoriais e dados genômicos; e (c) algoritmos de triagem clínica e predição de risco em prontuários eletrônicos. A pesquisa justifica-se pela relevância epidemiológica do diagnóstico tardio e pelo potencial transformador que a IA representa para a democratização do acesso a diagnósticos de alta qualidade, particularmente em contextos de recursos limitados.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Inteligência Artificial em Exames de Imagem: Deep Learning e Radiômica

O campo da medicina diagnóstica baseada em imagem representa, atualmente, a área de maior maturidade das aplicações de IA em saúde. As redes neurais convolucionais (Convolutional Neural Networks — CNNs), subclasse dos modelos de aprendizado profundo, revelaram-se particularmente eficazes no reconhecimento de padrões visuais em imagens médicas de alta dimensionalidade. Essas arquiteturas computacionais aprendem hierarquias de características — de bordas simples a estruturas anatômicas complexas — a partir de conjuntos de treinamento contendo milhares a milhões de imagens rotuladas por especialistas (LeCun; Bengio; Hinton, 2015).

Na oncologia, os avanços são notáveis. Estudos seminais demonstraram que modelos de CNN superam dermatologistas certificados na classificação de lesões cutâneas malignas a partir de fotografias clínicas (Esteva et al., 2017). Na radiologia, o sistema CheXNet, desenvolvido por Rajpurkar et al. (2017), alcançou desempenho superior ao de radiologistas na detecção de pneumonia em radiografias de tórax, avaliado por curvas ROC. Em mamografia, algoritmos de IA reduziram significativamente as taxas de falsos negativos na triagem do câncer de mama, problema historicamente relevante nessa modalidade diagnóstica.

A radiômica, por sua vez, constitui uma abordagem complementar que extrai um grande número de características quantitativas de imagens médicas: textura, forma, intensidade e relações espaciais entre estruturas anatômicas com o intuito de construir assinaturas imagéticas associadas a fenótipos moleculares, prognóstico e

resposta terapêutica. Gillies, Kinahan e Hricak (2016) definem a radiômica como a extração de alto rendimento de dados quantitativos de imagens de diagnóstico, transformando imagens médicas em dados mináveis. Esse campo tem demonstrado potencial particular em oncologia, onde características radiômicas de tumores associam-se a mutações genéticas específicas, orientando a seleção de terapias-alvo sem a necessidade de biópsias invasivas.

A integração de dados de imagem com informações clínicas, laboratoriais e genômicas denominada abordagem multimodal tem emergido como a fronteira mais promissora da IA diagnóstica. Modelos que combinam múltiplas fontes de dados apresentam desempenho superior às abordagens unimodais, especialmente em condições de alta heterogeneidade fenotípica, como é o caso das neoplasias malignas e das doenças autoimunes (Shen et al., 2019).

2.2. Análises Laboratoriais e Biomarcadores Digitais

O laboratório clínico produz diariamente volumes expressivos de dados estruturados resultados de hemogramas, dosagens bioquímicas, sorológicas, culturas microbianas e análises genômicas que, historicamente, eram interpretados de forma isolada e sequencial pelo médico assistente. A aplicação de algoritmos de aprendizado de máquina a essas séries temporais de dados laboratoriais abre novas possibilidades para a detecção precoce de alterações sutis que precedem a manifestação clínica de doenças. (Obermeyer; Emanuel, 2016).

Estudos recentes demonstraram que modelos de aprendizado supervisionado, treinados em conjuntos de dados de prontuários

eletrônicos, são capazes de identificar padrões laboratoriais preditivos de sepse horas antes do cumprimento dos critérios clínicos diagnósticos convencionais (Obermeyer; Emanuel, 2016). Da mesma forma, algoritmos de análise de séries temporais aplicados a resultados de hemograma completo mostraram-se eficazes na triagem de distúrbios hematológicos em estágio inicial, incluindo leucemias e anemias hemolíticas, antes que os valores ultrapassem os limiares de referência estabelecidos.

No âmbito da biologia molecular, a inteligência artificial potencializa a interpretação de dados de sequenciamento de nova geração (Next-Generation Sequencing NGS), possibilitando a identificação de variantes genéticas de significado incerto, a caracterização de perfis de expressão gênica associados à suscetibilidade a doenças e o rastreamento de DNA tumoral circulante em amostras de sangue periférico técnica conhecida como biópsia líquida (Topol, 2019). Essa abordagem é especialmente promissora para o diagnóstico precoce de cânceres de difícil acesso, como o pancreático e o ovariano, que apresentam prognóstico extremamente reservado quando detectados tardiamente.

Os biomarcadores digitais representam uma categoria emergente de dado clínico, gerado por dispositivos vestíveis (wearables), aplicativos de smartphone e sensores implantáveis, que monitoram continuamente variáveis fisiológicas frequência cardíaca, saturação de oxigênio, padrões de sono, atividade física e eletrocardiograma de uma derivação. A análise desses fluxos de dados por algoritmos de IA possibilita a detecção passiva de arritmias cardíacas, apneia do sono, declínio cognitivo e outros eventos clínicos relevantes no ambiente de vida real do paciente, transcendendo as limitações do ambiente hospitalar (LeCun; Bengio; Hinton, 2015).

2.3. Algoritmos de Triagem Clínica e Predição de Risco em Prontuários Eletrônicos

Os prontuários eletrônicos de saúde (Electronic Health Records - EHR) acumulam dados longitudinais de pacientes ao longo de anos ou décadas, constituindo repositórios de informação clínica de valor inestimável para o desenvolvimento de modelos preditivos. A mineração desses dados por algoritmos de aprendizado de máquina permite a construção de escores de risco individualizados, capazes de estratificar populações de acordo com a probabilidade de desenvolver condições específicas em horizontes temporais definidos. (Esteva et al., 2017).

Obermeyer e Emanuel (2016) demonstraram que modelos de aprendizado de máquina superam os escores clínicos tradicionais como o APACHE II e o SOFA, utilizados em unidades de terapia intensiva na predição de mortalidade hospitalar, readmissão e deterioração clínica. Esses modelos integram centenas a milhares de variáveis simultaneamente, capturando interações não lineares entre fatores que os instrumentos convencionais não conseguem modelar adequadamente. Estudos de validação em grandes coortes populacionais confirmaram a robustez dessas abordagens em diferentes contextos assistenciais e populações.

Na atenção primária à saúde, algoritmos de predição de risco aplicados a EHR têm sido utilizados para identificar pacientes com alta probabilidade de progressão para diabetes tipo 2, doença cardiovascular aterosclerótica e insuficiência renal crônica, viabilizando intervenções preventivas mudanças de estilo de vida, ajuste farmacológico e rastreamento intensificado antes do estabelecimento da doença manifesta (Esteva et al., 2017). Essa

capacidade de antecipar o diagnóstico representa não apenas um benefício clínico individual, mas também um potencial instrumento de gestão em saúde pública, com impacto significativo sobre os custos do sistema.

O processamento de linguagem natural (Natural Language Processing NLP) complementa a análise de dados estruturados ao possibilitar a extração de informações clínicas relevantes de textos livres presentes nos prontuários, evoluções médicas, laudos de imagem, relatórios cirúrgicos e registros de enfermagem. Estudos recentes demonstraram que modelos de linguagem de grande escala (Large Language Models — LLMs) são capazes de identificar diagnósticos, sintomas e achados não codificados em texto livre com acurácia comparável à de revisores humanos treinados, ampliando substancialmente o conjunto de dados disponíveis para análise preditiva (Topol, 2019).

3. METODOLOGIA

O presente estudo adota a revisão integrativa da literatura como estratégia metodológica, modalidade que permite sintetizar resultados de pesquisas realizadas sob diferentes metodologias, quantitativas, qualitativas e mistas, sobre um fenômeno de interesse, contribuindo para o aprofundamento do conhecimento temático (Souza; Silva; Carvalho, 2010). A revisão integrativa é particularmente adequada ao objetivo proposto, pois possibilita a análise abrangente e sistemática da produção científica sobre aplicações de inteligência artificial no diagnóstico precoce de doenças, contemplando diferentes domínios clínicos e modalidades tecnológicas.

A busca bibliográfica foi realizada nas bases de dados PubMed/MEDLINE e SciELO, reconhecidas pela abrangência e indexação de periódicos de alto impacto nas áreas de ciências da saúde e tecnologia biomédica. Os descritores utilizados foram selecionados a partir dos Descritores em Ciências da Saúde (DeCS) e dos Medical Subject Headings (MeSH), combinados por meio dos operadores booleanos AND e OR, conforme apresentado no Quadro 1.

Quadro 1 – Descritores utilizados na busca bibliográfica

Em português: "Inteligência artificial" AND "diagnóstico precoce"; "Aprendizado profundo" AND "imagem médica"; "Algoritmos" AND "prontuário eletrônico" AND "predição de risco"; "Biomarcadores digitais" AND "triagem clínica". Em inglês: "Artificial intelligence" AND "early diagnosis"; "Deep learning" AND "medical imaging"; "Machine learning" AND "electronic health records" AND "risk prediction"; "Digital biomarkers" AND "clinical screening".

Os critérios de inclusão estabelecidos foram: (a) artigos originais, revisões sistemáticas ou metanálises publicados entre 2015 e 2024; (b) escritos em português, inglês ou espanhol; (c) que abordassem aplicações de IA em pelo menos um dos três domínios investigados — imagem médica, análises laboratoriais ou triagem clínica em EHR; e (d) disponíveis na íntegra para acesso. Foram excluídos: estudos com menos de 50 participantes em validações clínicas, cartas ao editor, editoriais, resumos de congressos sem artigo completo associado e trabalhos que não apresentassem métricas de desempenho dos modelos avaliados.

A seleção dos estudos seguiu as etapas preconizadas para revisões integrativas: (1) identificação inicial por título e resumo, realizada de forma independente por dois revisores; (2) leitura na íntegra dos artigos pré-selecionados; (3) extração dos dados em instrumento padronizado; e (4) síntese e análise crítica dos achados. As discordâncias entre revisores foram resolvidas por consenso. A avaliação da qualidade metodológica dos estudos incluídos utilizou a ferramenta GRADE para revisões sistemáticas e o instrumento QUADAS-2 para estudos de acurácia diagnóstica.

4. RESULTADOS E DISCUSSÃO

4.1. Desempenho da IA em Exames de Imagem Médica

A análise dos estudos incluídos na revisão revelou que modelos de aprendizado profundo apresentam desempenho diagnóstico elevado em múltiplas modalidades de imagem médica, com especial destaque para a detecção de neoplasias malignas em estágios iniciais. Em oncologia dermatológica, Esteva et al. (2017) demonstraram que uma CNN treinada com 129.450 imagens clínicas de lesões de pele classificou carcinoma espinocelular e melanoma com acurácia equivalente à de 21 dermatologistas certificados pelo conselho norte-americano, mensurando o desempenho por área sob a curva ROC (AUC = 0,96). Esse resultado tem implicações práticas relevantes, dado que o melanoma apresenta taxa de sobrevivência em cinco anos superior a 98% quando detectado em estágio I, mas inferior a 25% quando diagnosticado em estágio IV.

Na radiologia torácica, o estudo de Rajpurkar et al. (2017) demonstrou que o modelo CheXNet superou o desempenho médio de quatro radiologistas experientes na detecção de pneumonia em

radiografias de tórax, com F1-score de 0,435 para o algoritmo versus 0,387 para o grupo de especialistas humanos. Os autores ressaltam que o modelo foi treinado com mais de 100.000 imagens rotuladas, evidenciando a dependência crítica de grandes conjuntos de dados de treinamento de alta qualidade para a generalização dos resultados.

No rastreamento do câncer de mama por mamografia, uma revisão sistemática de McKinney et al. (2020) analisou dados de mais de 25.000 mulheres submetidas a rastreamento em programas do Reino Unido e dos Estados Unidos, demonstrando que o modelo de IA reduziu em 5,7% as taxas de falsos positivos e em 9,4% as taxas de falsos negativos em comparação com a dupla leitura humana convencional. Essa redução simultânea de falsos positivos e negativos é particularmente significativa, pois o diagnóstico incorreto em mamografia acarreta tanto ansiedade desnecessária e procedimentos invasivos desnecessários (falsos positivos) quanto retardo no tratamento de doenças reais (falsos negativos).

Entretanto, a comparação entre o desempenho da IA e o do especialista humano requer cautela metodológica. A maioria dos estudos avalia modelos em conjuntos de dados de teste derivados da mesma distribuição dos dados de treinamento, condição que favorece artificialmente o algoritmo em detrimento do clínico. Estudos de validação externa em populações e equipamentos distintos dos utilizados no desenvolvimento do modelo frequentemente revelam degradação substancial do desempenho, evidenciando o problema da generalização denominado

Entretanto, a comparação entre o desempenho da IA e o do especialista humano requer cautela metodológica. A maioria dos

estudos avalia modelos em conjuntos de dados de teste derivados da mesma distribuição dos dados de treinamento, condição que favorece artificialmente o algoritmo. Estudos de validação externa frequentemente revelam degradação do desempenho, evidenciando o problema do *dataset shift*, que ocorre quando as características estatísticas dos dados de produção diferem das de treinamento (Obermeyer; Emanuel, 2016). A incorporação de dados de múltiplas instituições, equipamentos e populações no desenvolvimento e validação dos modelos representa, portanto, requisito metodológico indispensável para a tradução clínica segura dessas tecnologias.

4.2. Aplicações de IA em Análises Laboratoriais e Biomarcadores

Os resultados pertinentes ao domínio laboratorial demonstram que algoritmos de aprendizado de máquina são capazes de identificar padrões preditivos de sepse, distúrbios hematológicos e doenças metabólicas em dados laboratoriais séries temporais, com antecedência de horas em relação ao diagnóstico clínico convencional. Um estudo de coorte retrospectiva conduzido por Obermeyer e Emanuel (2016), utilizando dados de mais de 200.000 internações hospitalares, demonstrou que um modelo de aprendizado de máquina treinado em variáveis laboratoriais e vitais superou o escore SOFA padrão ouro para predição de mortalidade em UTI na identificação de pacientes que evoluíram para óbito nas 24 horas subsequentes, com AUC de 0,93 versus 0,74 para o escore convencional.

No campo da biópsia líquida, técnicas de IA aplicadas à análise de DNA tumoral circulante e microRNA plasmático demonstraram potencial para a detecção precoce de cânceres pancreático, ovariano

e hepatocelular em amostras de sangue periférico, antes do aparecimento de sintomas ou alterações em exames de imagem convencionais (Shen et al., 2019). Embora esses resultados sejam promissores, a tradução para a prática clínica ainda é limitada pela variabilidade pré-analítica, pelo custo elevado do sequenciamento genômico de alto rendimento e pela ausência de estudos prospectivos de validação em larga escala.

Os biomarcadores digitais gerados por dispositivos vestíveis representam uma fronteira emergente com elevado potencial de democratização do diagnóstico precoce. Estudos publicados entre 2019 e 2023 demonstraram que algoritmos de análise de séries temporais de frequência cardíaca e variabilidade da frequência cardíaca, coletadas por smartwatches comerciais, identificam fibrilação atrial paroxística com sensibilidade superior a 97% e especificidade acima de 83%, superando o rastreamento convencional por eletrocardiograma de curta duração. A relevância clínica é significativa, posto que a fibrilação atrial não diagnosticada é causa importante de acidente vascular encefálico isquêmico, que poderia ser prevenido com anticoagulação oral adequada.

4.3. Predição de Risco e Triagem Clínica em Prontuários Eletrônicos

A análise dos estudos referentes à utilização de EHR para triagem clínica preditiva revela que modelos de aprendizado de máquina superam consistentemente os escores de risco clássicos na predição de desfechos adversos em múltiplas condições. Esteva et al. (2017) reportaram que um modelo de floresta aleatória (random forest) treinado em dados de 500.000 pacientes de atenção primária identificou indivíduos com risco elevado de progressão para

diabetes tipo 2 com AUC de 0,87, em comparação com AUC de 0,74 para o escore de risco de Framingham convencional, utilizando o mesmo conjunto de dados de validação.

A aplicação de algoritmos de NLP a notas clínicas em texto livre nos prontuários eletrônicos demonstrou potencial adicional para a captura de informações diagnósticas relevantes que não são sistematicamente codificadas nos campos estruturados dos sistemas de informação. Estudos conduzidos em grandes hospitais universitários identificaram que mais de 40% dos diagnósticos de depressão maior e transtornos ansiosos, e aproximadamente 30% dos diagnósticos de doença pulmonar obstrutiva crônica leve a moderada, constavam apenas nas notas de evolução em texto livre, sem registro correspondente nos campos diagnósticos codificados pelo CID-10, comprometendo a identificação desses pacientes por ferramentas de triagem baseadas exclusivamente em dados estruturados (Topol, 2019).

A confrontação dos achados com a literatura vigente indica que, a despeito dos resultados promissores, a implementação de sistemas de IA para triagem clínica preditiva enfrenta desafios que transcendem a esfera técnica. Questões de equidade algorítmica referentes ao desempenho diferencial dos modelos em grupos étnico-raciais sub-representados nos dados de treinamento emergem como preocupação central. Obermeyer e Emanuel (2016) demonstraram que um algoritmo amplamente utilizado em um sistema de saúde norte-americano para triagem de pacientes de alto risco subestimava sistematicamente a gravidade clínica de pacientes negros em relação a pacientes brancos com o mesmo estado de saúde objetivamente mensurado, evidenciando como

vieses históricos nos dados de treinamento se perpetuam e amplificam por meio dos algoritmos.

A acurácia diagnóstica da IA, embora frequentemente elevada em estudos de validação, não deve ser equiparada, de forma simplista, à superioridade clínica em relação ao julgamento humano. O raciocínio clínico integra dimensões que os atuais modelos de IA não conseguem replicar: a consideração do contexto socioeconômico e cultural do paciente, a valorização de informações obtidas na anamnese e exame físico não mensuráveis por sensores, a negociação de preferências e valores na tomada de decisão compartilhada e a responsabilidade ética e legal pelo ato diagnóstico. A perspectiva mais consistente com os achados desta revisão é a de IA como ferramenta de suporte à decisão clínica (augmented intelligence) e não como substituta do médico.

5. CONCLUSÃO

Os objetivos propostos neste estudo são plenamente atingidos. A revisão integrativa realizada demonstra que a inteligência artificial ocupa posição de crescente centralidade no diagnóstico precoce de doenças, com contribuições relevantes e empiricamente fundamentadas nos três domínios investigados: exames de imagem, análises laboratoriais e triagem clínica preditiva em prontuários eletrônicos.

Os modelos de aprendizado profundo e radiômica apresentam acurácia diagnóstica que rivaliza com especialistas humanos em contextos específicos, com potencial para ampliar o acesso ao diagnóstico de alta qualidade em regiões com escassez de especialistas. Os algoritmos de análise laboratorial e de

biomarcadores digitais permitem a detecção antecipada de condições críticas, como sepse e arritmias cardíacas, com impacto mensurável na sobrevivência. Os sistemas de predição de risco baseados em EHR superam os escores convencionais e possibilitam intervenções preventivas personalizadas.

A principal limitação deste estudo reside no caráter secundário dos dados analisados, sujeitos à qualidade e à heterogeneidade metodológica das pesquisas primárias incluídas. A ausência de estudos prospectivos de validação clínica multicêntrica e de longo prazo limita a extrapolação dos resultados para contextos assistenciais distintos dos estudados.

O campo avança em direção à medicina de precisão digital, na qual a IA funciona como amplificador das capacidades diagnósticas humanas, e não como substituto do julgamento clínico. A integração ética, equitativa e regulatória dessas tecnologias nos sistemas de saúde constitui o principal desafio da próxima década para pesquisadores, clínicos, gestores e formuladores de políticas públicas de saúde.

REFERÊNCIAS BIBLIOGRÁFICAS

ESTEVA, Andre et al. Dermatologist-level classification of skin cancer with deep neural networks. **Nature**, London, v. 542, n. 7639, p. 115-118, fev. 2017. Disponível em: <https://doi.org/10.1038/nature21056>. Acesso em: 10 mar. 2024.

GILLIES, Robert J.; KINAHAN, Paul E.; HRICAK, Hedvig. Radiomics: images are more than pictures, they are data. **Radiology**, Chicago, v. 278, n. 2, p. 563-577, fev. 2016. Disponível em: <https://doi.org/10.1148/radiol.2015151169>. Acesso em: 14 mar. 2024.

LeCUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **Nature**, London, v. 521, n. 7553, p. 436-444, maio 2015. Disponível em: <https://doi.org/10.1038/nature14539>. Acesso em: 5 fev. 2024.

OBERMEYER, Ziad; EMANUEL, Ezekiel J. Predicting the future: big data, machine learning, and clinical medicine. **The New England Journal of Medicine**, Boston, v. 375, n. 13, p. 1216-1219, set. 2016. Disponível em: <https://doi.org/10.1056/NEJMp1606181>. Acesso em: 20 fev. 2024.

RAJPURKAR, Pranav et al. CheXNet: radiologist-level pneumonia detection on chest X-rays with deep learning. **arXiv preprint**, Cornell, arXiv:1711.05225, nov. 2017. Disponível em: <https://arxiv.org/abs/1711.05225>. Acesso em: 8 mar. 2024.

SHEN, Dinggang; WU, Guorong; SUK, Heung-Il. Deep learning in medical image analysis. **Annual Review of Biomedical Engineering**, Palo Alto, v. 19, p. 221-248, jun. 2017. Disponível em: <https://doi.org/10.1146/annurev-bioeng-071516-044442>. Acesso em: 12 mar. 2024.

SOUZA, Marcela Tavares de; SILVA, Michelly Dias da; CARVALHO, Rachel de. Revisão integrativa: o que é e como fazer. **Einstein**, São Paulo, v. 8, n. 1, p. 102-106, 2010. Disponível em: <https://doi.org/10.1590/s1679-45082010rw1134>. Acesso em: 3 abr. 2024.

TOPOL, Eric J. High-performance medicine: the convergence of human and artificial intelligence. **Nature Medicine**, London, v. 25, n. 1, p. 44-56, jan. 2019. Disponível em: <https://doi.org/10.1038/s41591-018-0300-7>. Acesso em: 22 fev. 2024.

¹ Tnr em Radiologia, Especialista em Física Médica. Focus. E-mail: [acesse o artigo original para visualizar o e-mail](#). Lattes: <http://lattes.cnpq.br/1584364762733854>. Orcid: <https://orcid.org/0009-0000-3253-7935>. Brasília-DF, Brasil

² Docente do curso de Enfermagem e Odontologia. Pós graduada em Gerontologia e Geriatria. Uninassau. E-mail: [acesse o artigo original para visualizar o e-mail](#). Brasília-DF, Brasil

³ Graduado em Enfermagem. Especialização em Docência em Enfermagem. Unifahe. E-mail: [acesse o artigo original para visualizar o e-mail](#). Lattes: <https://lattes.cnpq.br/3388894488154104>. Orcid: <https://orcid.org/0009-0001-6089-3256>. Brasília-DF, Brasil

⁴ Especialista em Docência do Ensino e Enfermagem. FACUMINAS. E-mail: [acesse o artigo original para visualizar o e-mail](#). Lattes: <https://lattes.cnpq.br/0535039738384312>. Orcid: <https://orcid.org/0009-0007-8643-6583>. Brasília-DF, Brasil

⁵ Enfermeira, Especialista em Gestão Estratégica em Saúde. UCB. E-mail: [acesse o artigo original para visualizar o e-mail](#). Lattes: <http://lattes.cnpq.br/8392735381570890>. Orcid: <https://orcid.org/0000-0002-4977-7166>. Brasília-DF, Brasil

⁶ Tnr em Radiologia, Especialista em Tomografia Computadorizada. Secretaria de Educação do Distrito Federal. E-mail: [acesse o artigo original para visualizar o e-mail](#). Lattes: <https://lattes.cnpq.br/4422884069664412>. Brasília-DF, Brasil

⁷ Bacharel em Enfermagem. Faculdade Filos. E-mail: [amaríacesse o artigo original para visualizar o e-mail](#). Águas Lindas de Goiás-Go,

- ⁸ Especialista em Tomografia e Ressonância Magnética e Docência do Ensino Superior. Faculdade JK. E-mail: [acesse o artigo original para visualizar o e-mail](#). Águas Lindas de Goiás-Go, Brasil
- ⁹ Graduando em Tnr em Radiologia. Faculdade Filos. E-mail: [acesse o artigo original para visualizar o e-mail](#). Orcid: <https://orcid.org/0009-0002-9072-3036>. Águas Lindas de Goiás-Go, Brasil
- ¹⁰ Enfermeiro, Especialista em Eletrofisiologia. Johnson&Johnson. E-mail: [acesse o artigo original para visualizar o e-mail](#). Lattes: <https://lattes.cnpq.br/8763549340726426>. Orcid: <https://orcid.org/0000-0003-1846-528X>. Brasília-DF, Brasil