

CAPITULO DE LIVRO - SAÚDE E TRANSFORMAÇÃO DIGITAL

**APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO POR  
IMAGEM MÉDICA: USO DE REDES NEURAIIS NA RADIOLOGIA,  
TOMOGRAFIA, ULTRASSOM E DETECÇÃO DE PATOLOGIAS**

*Virginia Ferreira Couto Costa (virginiafecc@gmail.com)*

*Ana Clara Pires Rezende (pranaclara04@gmail.com)*

*Leonardo Gotardo Araujo (leogotardoaraujo@gmail.com)*

*Maria Luiza De Jesus Nunes (marialuizanunes2004@hotmail.com)*

COSTA, Virgínia Ferreira Couto<sup>1</sup>

REZENDE, Ana Clara Pires<sup>2</sup>

ARAÚJO, Leonardo Gotardo<sup>3</sup>

NUNES, Maria Luiza de Jesus<sup>4</sup>

RESUMO

Introdução: a integração da Inteligência Artificial (IA) ao diagnóstico por imagem médica tem revolucionado a prática clínica, oferecendo novas possibilidades de precisão, rapidez e padronização dos laudos (Litjens et al., 2017). Objetivo: analisar as principais aplicações da IA, com foco no uso de redes neurais convolucionais (CNNs) na radiologia, tomografia computadorizada e ultrassonografia, discutindo desempenho, benefícios e limitações (Esteva et al., 2019). Métodos: revisão narrativa integrativa realizada entre 2018 e 2025, com busca nas bases PubMed, SciELO, IEEE Xplore e ScienceDirect, selecionando estudos originais, revisões sistemáticas e diretrizes clínicas que apresentassem métricas de acurácia, sensibilidade e especificidade (OMS, 2021). Resultados: a IA demonstrou desempenho comparável ou superior ao de radiologistas em tarefas de detecção de patologias, alcançando acurácia média de 90–97 %, sensibilidade de 88–96 % e especificidade de 85–94 % (The Lancet Digital Health, 2024; Radiology, 2025), além de reduzir o tempo de leitura e otimizar fluxos operacionais em serviços de urgência e radiologia geral (FDA, 2024). Discussão: observam-se avanços significativos em triagem automatizada, reconstrução de imagem e segmentação tumoral, embora persistam desafios quanto a viés algorítmico, validação multicêntrica e governança ética (OMS, 2021; The Lancet Digital Health, 2024). Conclusões: a IA representa ferramenta complementar indispensável ao diagnóstico por imagem, contribuindo para maior eficiência e equidade assistencial, desde que implementada sob princípios éticos, transparência e supervisão profissional (Litjens et al., 2017; Esteva et al., 2019; OMS, 2021).

Autoria principal: Virgínia Ferreira Couto Costa – [virginiafecc@gmail.com](mailto:virginiafecc@gmail.com)

<sup>1</sup> Virgínia Ferreira Couto Costa – Acadêmica de Medicina – IMEPAC – Araguari–MG – [virginiafecc@gmail.com](mailto:virginiafecc@gmail.com)

<sup>2</sup> Ana Clara Pires Rezende – Acadêmica de Medicina – IMEPAC – Araguari–MG – [pranaclara04@gmail.com](mailto:pranaclara04@gmail.com)

<sup>3</sup> Leonardo Gotardo Araújo – Acadêmico de Engenharia Biomédica – UFU – Uberlândia–MG – [leogitardoaraujo@gmail.com](mailto:leogitardoaraujo@gmail.com)

<sup>4</sup> Maria Luiza de Jesus Nunes – Acadêmica de Medicina – IMEPAC – Araguari–MG – marialuizanunes2004@hotmail.com

## 1. INTRODUÇÃO

O diagnóstico por imagem é um dos pilares da medicina moderna, permitindo a observação não invasiva de estruturas anatômicas e processos fisiológicos (Yasaka & Abe, 2018). O progresso tecnológico nas últimas décadas, especialmente com o advento da radiologia digital, produziu volumes massivos de dados, tornando-se inviável para o profissional humano analisar e correlacionar todas as informações disponíveis em tempo hábil. Nesse cenário, a Inteligência Artificial (IA) emergiu como uma das inovações mais transformadoras da medicina contemporânea, inaugurando uma nova era de diagnóstico assistido por computador (Litjens et al., 2017).

A IA, de forma ampla, consiste na capacidade de sistemas computacionais executarem tarefas que, tradicionalmente, exigiriam inteligência humana — como reconhecimento de padrões, aprendizado a partir da experiência e tomada de decisões (Russell & Norvig, 2021). No campo da saúde, a subárea de aprendizado profundo (deep learning), baseada em redes neurais convolucionais (CNNs), tem se destacado pela habilidade em interpretar imagens complexas com precisão similar ou superior à de especialistas (Esteve et al., 2019; Shen, Wu & Suk, 2017). Essas redes são inspiradas na arquitetura do córtex visual humano e possuem múltiplas camadas de processamento capazes de extrair automaticamente características relevantes das imagens, eliminando a necessidade de intervenção manual no reconhecimento de padrões.

Os primeiros experimentos com IA aplicada à medicina datam da década de 1970, mas somente com o aumento do poder computacional e a disponibilidade de grandes bancos de dados (“big data”) é que se tornou viável treinar redes neurais profundas com milhões de parâmetros (LeCun, Bengio & Hinton, 2015). Em 2016, a publicação de Litjens et al. marcou um divisor de águas ao demonstrar que algoritmos de deep learning poderiam identificar lesões de

câncer de pele com desempenho comparável ao de dermatologistas (Litjens et al., 2017). A partir de então, surgiram múltiplas aplicações em radiologia, patologia digital, oftalmologia e cardiologia, consolidando a IA como ferramenta de apoio diagnóstico em diversos contextos clínicos (The Lancet Digital Health, 2024).

A radiologia, por sua natureza imagética e baseada em padrões, tornou-se o ambiente mais fértil para o desenvolvimento de modelos de IA (Yasaka & Abe, 2018). Exames como radiografias, tomografias computadorizadas (TC) e ressonâncias magnéticas (RM) geram dados visuais de alta resolução, os quais podem ser utilizados para treinar redes capazes de detectar anomalias, classificar tecidos e até prever desfechos clínicos. Diversos estudos apontam que a IA é capaz de reconhecer achados sutis, muitas vezes imperceptíveis ao olho humano, contribuindo para diagnósticos mais precoces e intervenções oportunas (Radiology, 2025; Esteva et al., 2019).

Além do impacto clínico, a IA também promove transformações na gestão e eficiência operacional. Sistemas automatizados auxiliam na priorização de casos críticos, organizando listas de trabalho de radiologistas e acelerando o tempo de resposta em emergências (FDA, 2024). Em hospitais de grande porte, onde milhares de exames são realizados diariamente, algoritmos de triagem automática ajudam a reduzir o acúmulo de imagens não analisadas, otimizando fluxos de trabalho e melhorando a segurança do paciente (Stanford AIM, 2023).

Contudo, a incorporação da IA ao diagnóstico por imagem não está isenta de desafios. As questões éticas e regulatórias ocupam lugar central na discussão contemporânea. A OMS (2021) alerta para os riscos de viés algorítmico, que podem reproduzir desigualdades estruturais se os dados de treinamento forem desbalanceados. A transparência e explicabilidade dos modelos (XAI – Explainable Artificial Intelligence) são essenciais para garantir a confiança do profissional e do paciente (The Lancet Digital Health, 2024). Além disso, a Lei Geral de Proteção de Dados (LGPD – Lei nº 13.709/2018) impôs novas exigências sobre tratamento e anonimização de dados médicos, impactando diretamente o desenvolvimento e a validação de algoritmos clínicos (Brasil, 2018).

No contexto brasileiro, a integração entre tecnologia e prática médica apresenta peculiaridades. Embora o país possua polos de excelência em informática em saúde, como os programas da Fiocruz e da USP, ainda existem desigualdades regionais significativas quanto à infraestrutura digital e acesso a equipamentos de imagem (Cunha et al., 2023). Dessa forma, a adoção da IA deve ser vista não apenas como um avanço tecnológico, mas como um instrumento de equidade assistencial, capaz de reduzir disparidades diagnósticas em regiões carentes (OMS, 2021).

As aplicações práticas da IA abrangem múltiplas modalidades. Na radiografia torácica, por exemplo, redes neurais foram capazes de detectar pneumonia, tuberculose e nódulos pulmonares com alto grau de precisão (Yasaka & Abe, 2018). Na tomografia computadorizada, algoritmos de segmentação identificam hemorragias intracranianas, aneurismas e tumores hepáticos com desempenho superior ao humano em sensibilidade e especificidade (The Lancet Digital Health, 2024). Já na ultrassonografia, o uso da IA contribui para reduzir a variabilidade entre operadores, automatizar medições e apoiar diagnósticos em tempo real (Nature Biomedical Engineering, 2023).

A introdução dessas tecnologias também gerou novos papéis profissionais. O radiologista contemporâneo atua não apenas como intérprete de imagens, mas como gestor de informações clínicas e supervisor da IA, responsável por validar laudos automatizados e contextualizá-los clinicamente (Radiology, 2025). Essa redefinição do papel médico exige novas competências, como literacia digital, ética em IA e interpretação de modelos estatísticos (Esteve et al., 2019).

Outro ponto relevante é o potencial preditivo dos algoritmos. Diferentemente das abordagens convencionais, que se concentram na detecção de doenças já estabelecidas, a IA permite estimar riscos e prognósticos com base em padrões sutis presentes nas imagens. Estudos recentes demonstraram que redes neurais podem prever o risco de infarto ou reinternação a partir de radiografias torácicas aparentemente normais (The Lancet Digital Health, 2024). Essa capacidade de antecipar eventos abre caminhos para uma medicina mais preventiva e personalizada (OMS, 2021).

No entanto, a transformação digital não se resume ao avanço técnico. Ela implica mudanças na cultura institucional, na formação profissional e na organização dos serviços de saúde. A adoção bem-sucedida da IA depende de programas de capacitação contínua, integração multidisciplinar e parcerias entre academia, indústria e governo (OMS, 2021; FDA, 2024). Somente com essa sinergia será possível garantir que a IA seja uma ferramenta de apoio e não de substituição do profissional humano.

Assim, esta introdução estabelece o panorama conceitual e contextual para o desenvolvimento do capítulo, que a seguir aprofundará as metodologias de análise da literatura, os resultados encontrados nas principais modalidades de imagem — radiologia, tomografia e ultrassonografia — e as discussões éticas, técnicas e regulatórias que moldam o futuro da inteligência artificial aplicada ao diagnóstico médico.

## 2. METODOLOGIA

O presente estudo constitui uma revisão narrativa integrativa da literatura científica, conduzida entre janeiro e outubro de 2025, com o objetivo de sintetizar as evidências disponíveis acerca das aplicações da Inteligência Artificial (IA) no diagnóstico por imagem médica. A revisão narrativa foi escolhida por permitir uma abordagem ampla, reflexiva e interpretativa do tema, considerando diferentes perspectivas teóricas, tecnológicas e éticas (Grant & Booth, 2009). Essa metodologia é amplamente utilizada em áreas emergentes, como a IA em saúde, nas quais o conhecimento é dinâmico e as fronteiras conceituais ainda estão em construção (Whittemore & Knafl, 2005).

A coleta de dados foi realizada por meio de busca sistematizada nas bases PubMed, SciELO, IEEE Xplore, ScienceDirect e Web of Science, selecionando publicações entre 2018 e 2025. Foram utilizadas combinações dos descritores em português e inglês: “inteligência artificial”, “deep learning”, “rede neural convolucional”, “radiologia”, “tomografia computadorizada”, “ultrassonografia”, “diagnóstico por imagem”, “detecção de patologias” e “machine learning in medical imaging”. Além disso, documentos técnicos e relatórios de órgãos internacionais, como a Organização Mundial da Saúde (OMS) e a Food and

Drug Administration (FDA), também foram incluídos para ampliar a base de evidências (OMS, 2021; FDA, 2024).

Foram incluídos artigos originais, revisões sistemáticas, meta-análises, relatórios técnicos e diretrizes clínicas que abordassem o uso da IA em radiologia, tomografia ou ultrassonografia, desde que apresentassem dados quantitativos de desempenho — como acurácia, sensibilidade, especificidade e valor preditivo positivo. Excluíram-se estudos puramente experimentais sem validação clínica, publicações duplicadas e artigos com escopo restrito a desenvolvimento de algoritmos sem aplicação diagnóstica.

A análise dos dados seguiu abordagem qualitativa e descritiva, com foco na comparação entre o desempenho da IA e o de especialistas humanos, bem como na identificação de benefícios operacionais, limitações e implicações éticas. As informações extraídas foram agrupadas por modalidade de imagem (radiologia, tomografia e ultrassonografia), tipo de algoritmo e desfechos clínicos avaliados. Para garantir a consistência dos achados, priorizou-se a triangulação de fontes e a reprodutibilidade dos resultados apresentados em mais de um estudo independente (Whittemore & Knafl, 2005).

Por fim, a interpretação dos resultados foi guiada pelos princípios da Medicina Baseada em Evidências (MBE), considerando o nível de evidência e a força das recomendações, conforme o sistema GRADE. Essa integração entre análise narrativa e fundamentação metodológica rigorosa assegurou uma visão abrangente e crítica sobre o papel atual e futuro da IA no diagnóstico por imagem (Guyatt et al., 2011).

### 3. RESULTADOS E DISCUSSÕES

#### 3.1 Radiologia

A radiologia representa a especialidade médica mais diretamente impactada pela inteligência artificial. Desde o advento das redes neurais convolucionais (CNNs), a interpretação automatizada de imagens radiográficas e tomográficas tornou-se uma realidade clínica em múltiplos países (Litjens et al., 2017; Yasaka & Abe, 2018). As CNNs são especialmente eficazes na detecção de padrões

visuais complexos, como densidades pulmonares, fraturas e calcificações, atuando como uma segunda leitura automatizada que aumenta a segurança diagnóstica.

Estudos multicêntricos demonstram que a IA é capaz de identificar pneumonia, tuberculose, colapso pulmonar e nódulos malignos com acurácia superior a 94%, sensibilidade de 95% e especificidade média de 93% (The Lancet Digital Health, 2024). Esses índices superam o desempenho médio de radiologistas generalistas, que variam entre 85% e 90% de acurácia em condições similares (Radiology, 2025). A incorporação desses algoritmos reduziu em até 45% o tempo médio de emissão de laudos em serviços de urgência e emergência, segundo dados do Stanford Artificial Intelligence in Medicine Laboratory (Stanford AIM, 2023).

Outro campo de aplicação da IA é a radiografia musculoesquelética, na qual algoritmos treinados com grandes conjuntos de dados conseguem identificar fraturas sutis de ossos longos, escafóide e fêmur proximal com precisão superior à de residentes em radiologia (The Lancet Digital Health, 2024). Isso tem especial relevância em ambientes de pronto-atendimento com alta demanda e escassez de especialistas, onde a triagem automatizada pode priorizar casos mais graves.

Além da detecção de patologias, a IA tem desempenhado papel crescente na quantificação automatizada de achados. Ferramentas de segmentação baseadas em aprendizado profundo permitem medir volumes pulmonares, densidade óssea e extensão de infiltrados, produzindo dados quantitativos que auxiliam o acompanhamento longitudinal de doenças (Esteva et al., 2019). A integração entre essas medições e o prontuário eletrônico do paciente (PEP) facilita análises preditivas, permitindo identificar pacientes com risco aumentado de progressão de determinadas patologias.

A literatura também destaca o uso da IA em mamografia digital. Um estudo publicado na Radiology (2025) mostrou que um algoritmo treinado com mais de um milhão de imagens foi capaz de detectar câncer de mama com sensibilidade de 94% e especificidade de 89%, reduzindo falsos negativos em 23% em comparação com a leitura convencional. O mesmo estudo demonstrou que,

quando o radiologista avaliava a mamografia com o auxílio da IA, o desempenho global aumentava em 8%, evidenciando o caráter colaborativo da tecnologia.

No entanto, a IA na radiologia também levanta preocupações éticas e de responsabilidade profissional. A OMS (2021) ressalta que a decisão clínica deve permanecer sob supervisão humana, sendo o algoritmo apenas um suporte diagnóstico. O conceito de human-in-the-loop — em que o especialista valida a interpretação automatizada — é considerado essencial para garantir a segurança do paciente e a confiabilidade dos resultados (The Lancet Digital Health, 2024).

Há também o desafio do viés de dados. A maioria dos modelos é treinada em bancos de imagens de países desenvolvidos, o que pode limitar sua aplicabilidade em populações com características diferentes. Estudos brasileiros destacam que diferenças em densidade óssea, prevalência de doenças infecciosas e qualidade do equipamento de imagem podem afetar o desempenho do algoritmo (Cunha et al., 2023). Assim, a adaptação regional e a validação local dos modelos são passos fundamentais antes da adoção em larga escala.

De modo geral, as evidências apontam que a IA não substitui o radiologista, mas amplia sua capacidade de detecção e interpretação, permitindo maior foco em análises complexas e decisões clínicas contextualizadas (Esteva et al., 2019). O futuro da radiologia tende a ser colaborativo, com uma sinergia entre a inteligência humana e artificial, apoiada por sistemas de aprendizado contínuo que se atualizam à medida que novos dados são inseridos (Radiology, 2025).

### 3.2 Tomografia Computadorizada

A tomografia computadorizada (TC) é uma das modalidades mais beneficiadas pela aplicação de IA, devido à sua alta resolução espacial e grande volume de dados por exame (The Lancet Digital Health, 2024). A TC é amplamente utilizada em emergências médicas, oncologia, neurologia e cardiologia, e o uso

de algoritmos de aprendizado profundo tem aprimorado tanto a qualidade das imagens quanto a eficiência diagnóstica (FDA, 2024).

Os modelos de IA aplicados à TC podem ser classificados em três categorias principais: reconstrução de imagem, detecção de anomalias e quantificação automatizada. No campo da reconstrução, algoritmos de aprendizado profundo permitem gerar imagens de alta qualidade com doses significativamente menores de radiação, reduzindo a exposição do paciente em até 40% sem comprometer a nitidez diagnóstica (FDA, 2024). Isso é particularmente relevante em exames repetidos, como os realizados em pacientes oncológicos ou pediátricos.

Na detecção de anomalias, as redes neurais têm se mostrado altamente eficazes. Modelos treinados para identificar hemorragias intracranianas em tomografias de crânio alcançaram acurácia de 97% e sensibilidade de 96%, superando o desempenho médio de radiologistas gerais (The Lancet Digital Health, 2024). Estudos similares reportaram que a IA pode detectar aneurismas cerebrais e tromboembolismo pulmonar com taxas de acerto comparáveis às de especialistas neurorradiologistas (Radiology, 2025).

Em oncologia, a IA tem revolucionado a segmentação de tumores e o planejamento de terapias. Ferramentas baseadas em aprendizado profundo conseguem delinear automaticamente lesões em fígado, pulmão e cérebro, permitindo medições volumétricas precisas que auxiliam na avaliação de resposta ao tratamento (Esteve et al., 2019). Isso reduz o tempo gasto em tarefas manuais e aumenta a padronização entre diferentes profissionais.

Outro avanço é o uso de IA em angiotomografia coronariana, onde algoritmos analisam o grau de estenose e a morfologia das placas ateroscleróticas. De acordo com a Nature Medicine (2023), a IA foi capaz de prever eventos cardiovasculares futuros com base em características invisíveis à inspeção humana direta, abrindo espaço para a estratificação preditiva de risco (Nature Medicine, 2023).

A literatura também discute o papel da IA na tomografia de tórax durante a pandemia de COVID-19. Modelos de aprendizado profundo foram

desenvolvidos para identificar padrões de pneumonia viral, com acurácia média de 95% na diferenciação entre COVID-19 e outras pneumonias (The Lancet Digital Health, 2024). Além disso, a IA auxiliou na quantificação automática da extensão pulmonar comprometida, servindo como ferramenta prognóstica para internações prolongadas e necessidade de ventilação mecânica (Radiology, 2025).

A aplicação de IA na TC também abrange a radiômica, campo que transforma dados de imagem em informações quantitativas extraídas automaticamente. Essa abordagem permite correlacionar características invisíveis a olho nu com marcadores genéticos, resposta terapêutica e prognóstico (Lundervold & Lundervold, 2019). A radiômica impulsionada pela IA está se tornando essencial na medicina de precisão, promovendo decisões terapêuticas individualizadas com base no perfil biológico e radiológico de cada paciente (OMS, 2021).

Entretanto, apesar de seus benefícios, a IA na tomografia enfrenta barreiras de implementação clínica e validação regulatória. A FDA (2024) reforça que apenas modelos validados multicentricamente e com transparência nos dados de treinamento podem ser aprovados para uso clínico. A falta de padronização nos protocolos de aquisição e reconstrução de imagem pode comprometer a generalização dos algoritmos (OMS, 2021). Portanto, esforços internacionais estão sendo realizados para criar bancos de dados compartilhados e auditáveis que sirvam como referência global de treinamento e validação.

### 3.3 Ultrassonografia

A ultrassonografia (USG), também conhecida como ecografia, representa uma das modalidades de imagem mais acessíveis, seguras e amplamente utilizadas na prática médica. Sua principal vantagem é o caráter não invasivo, a ausência de radiação ionizante e o baixo custo operacional, o que a torna indispensável em especialidades como ginecologia, obstetrícia, cardiologia e emergência (Radiology, 2025). Entretanto, o exame depende fortemente da habilidade do operador, o que gera variabilidade nos resultados e limitações diagnósticas em ambientes com profissionais menos experientes. É nesse contexto que a Inteligência Artificial (IA) tem se mostrado uma ferramenta revolucionária,

reduzindo a dependência do operador e padronizando a interpretação das imagens (Nature Biomedical Engineering, 2023).

A aplicação de redes neurais convolucionais (CNNs) em ultrassonografia tem permitido avanços significativos em detecção de anomalias estruturais, avaliação de fluxo sanguíneo e classificação de tecidos. Estudos apontam que algoritmos de aprendizado profundo são capazes de identificar, em tempo real, órgãos e patologias com precisão superior à humana em contextos específicos (Litjens et al., 2017; Esteva et al., 2019). Em um estudo multicêntrico envolvendo mais de 12 mil imagens de tireoide, um modelo de IA treinado para diferenciar nódulos benignos e malignos alcançou acurácia de 91%, sensibilidade de 93% e especificidade de 91%, superando a performance média dos especialistas participantes (The Lancet Digital Health, 2024).

Na obstetrícia, algoritmos de IA aplicados à ultrassonografia tridimensional (3D) têm contribuído para automatizar medições fetais, identificar malformações estruturais e avaliar o crescimento intrauterino com elevada precisão. Segundo um estudo publicado na Nature Biomedical Engineering (2023), sistemas automatizados de análise de imagem foram capazes de reduzir em 35% o tempo médio de exame obstétrico, mantendo a mesma confiabilidade diagnóstica, o que representa uma economia considerável de tempo clínico e aumento de produtividade nos serviços públicos e privados.

Em cardiologia, a IA aplicada ao ecocardiograma tem ampliado a capacidade de análise quantitativa do coração. Modelos de aprendizado profundo conseguem medir a fração de ejeção, o volume diastólico final e a deformação miocárdica (strain) com precisão comparável à de especialistas humanos (Lundervold & Lundervold, 2019). Além disso, a IA auxilia na detecção precoce de cardiomiopatias subclínicas e na análise automática de fluxos doppler, o que permite maior reprodutibilidade dos achados. Essa padronização é crucial em grandes serviços de saúde, nos quais múltiplos profissionais realizam exames diariamente, reduzindo o risco de erro interobservador.

Outro campo emergente é a aplicação da IA em ultrassonografia point-of-care (POCUS), modalidade portátil que tem se tornado indispensável em unidades de emergência e terapia intensiva. A IA contribui para orientar o posicionamento

da sonda, reconhecer estruturas anatômicas automaticamente e alertar sobre achados anormais durante o exame (FDA, 2024). Essa tecnologia permite que médicos não radiologistas, como intensivistas ou clínicos gerais, utilizem o ultrassom de maneira mais segura e eficaz, democratizando o acesso ao diagnóstico por imagem em regiões com recursos limitados (OMS, 2021).

A IA também tem papel relevante na educação médica. Softwares baseados em aprendizado profundo são usados para treinar estudantes e residentes em simulações realistas, fornecendo feedback imediato sobre a qualidade das imagens adquiridas e sobre o enquadramento anatômico correto (Nature Biomedical Engineering, 2023). Isso contribui para reduzir o tempo de aprendizado e melhorar a proficiência técnica dos futuros profissionais.

Apesar dos avanços, a adoção da IA na ultrassonografia ainda enfrenta limitações. A variabilidade dos equipamentos, a heterogeneidade dos protocolos de aquisição e a baixa qualidade de algumas imagens clínicas dificultam a padronização dos algoritmos (Radiology, 2025). Além disso, o alto custo de atualização tecnológica e a necessidade de conectividade constante para processamento em nuvem ainda representam desafios em países de renda média, como o Brasil.

Mesmo com essas barreiras, o consenso na literatura é que a IA se consolidará como parte integrante dos sistemas de ultrassonografia, atuando como uma extensão cognitiva do profissional e promovendo diagnósticos mais rápidos, precisos e acessíveis (The Lancet Digital Health, 2024; OMS, 2021).

### 3.4 Síntese comparativa entre modalidades de imagem

A comparação do desempenho da Inteligência Artificial em diferentes modalidades de imagem revela um panorama consistente: os algoritmos de deep learning têm desempenho igual ou superior ao humano em tarefas específicas, especialmente naquelas que envolvem reconhecimento de padrões visuais sutis e análise quantitativa de estruturas complexas (Litjens et al., 2017; Radiology, 2025).

Na radiografia, os modelos de IA alcançam acurácia média de 94%, com sensibilidade de 95% e especificidade de 93%, superando radiologistas generalistas em diagnósticos de pneumonia, fraturas e nódulos pulmonares (Yasaka & Abe, 2018; The Lancet Digital Health, 2024). Essa modalidade é a mais acessível e frequentemente utilizada como porta de entrada nos serviços de saúde, o que reforça o potencial impacto da IA na triagem automatizada de grandes volumes de exames.

Na tomografia computadorizada, os algoritmos demonstram o maior nível de maturidade clínica, com acurácia média de 97% e sensibilidade de 96%, sobretudo em detecção de hemorragias intracranianas, tumores e doenças pulmonares (Radiology, 2025). Essa superioridade decorre da riqueza de dados tridimensionais e da padronização dos protocolos de aquisição, o que favorece o treinamento de redes neurais com grande volume de exemplos.

A ultrassonografia, por sua vez, apresenta acurácia média de 92%, sensibilidade de 93% e especificidade de 91%, índices próximos aos da tomografia, mas ainda ligeiramente inferiores devido à variabilidade do operador e à heterogeneidade dos equipamentos (Nature Biomedical Engineering, 2023). Apesar disso, sua versatilidade e baixo custo a tornam a modalidade com maior potencial de expansão nos sistemas de saúde de países em desenvolvimento (OMS, 2021).

De maneira geral, observa-se que a IA não substitui o especialista humano, mas complementa sua atuação, reduzindo erros de interpretação, acelerando fluxos operacionais e ampliando a cobertura diagnóstica em regiões com escassez de profissionais. Além dos ganhos em precisão, os estudos relatam redução média de 30% no tempo de emissão de laudos e aumento de 25% na produtividade dos serviços que implementaram sistemas de triagem automatizada (FDA, 2024; Stanford AIM, 2023).

Outro benefício relevante é a padronização dos relatórios diagnósticos, que minimiza discrepâncias entre diferentes radiologistas e garante maior reprodutibilidade. Essa padronização é especialmente importante em contextos multicêntricos, como redes hospitalares e estudos clínicos, nos quais a consistência das interpretações é essencial (The Lancet Digital Health, 2024).

No entanto, é fundamental reconhecer que o desempenho elevado da IA depende da qualidade e representatividade dos dados de treinamento. Modelos treinados em amostras enviesadas podem apresentar falhas sistemáticas, levando a diagnósticos incorretos em populações sub-representadas (OMS, 2021). Por isso, a validação multicêntrica e a auditoria contínua dos sistemas são requisitos imprescindíveis para seu uso clínico seguro (FDA, 2024).

Em síntese, as três modalidades — radiografia, tomografia e ultrassonografia — ilustram diferentes estágios de maturidade tecnológica, mas convergem para o mesmo objetivo: tornar o diagnóstico mais rápido, preciso e equitativo, com suporte inteligente que amplifica a capacidade humana sem substituí-la (Radiology, 2025; Esteva et al., 2019).

### 3.5 Aspectos éticos e regulatórios

O uso de Inteligência Artificial em saúde suscita discussões éticas complexas, que envolvem responsabilidade, privacidade e equidade. A Organização Mundial da Saúde (OMS, 2021) destaca que a IA deve sempre operar sob os princípios da beneficência, não maleficência, autonomia e justiça. Isso significa que seu uso deve gerar benefícios comprovados aos pacientes, minimizar riscos, respeitar a autonomia dos profissionais e não ampliar desigualdades no acesso à saúde.

No Brasil, a Lei Geral de Proteção de Dados Pessoais (LGPD – Lei nº 13.709/2018) estabeleceu regras rigorosas para o tratamento de dados sensíveis, incluindo imagens médicas. Ela exige consentimento informado do paciente, anonimização dos dados e segurança criptográfica nos processos de armazenamento e transmissão (Brasil, 2018). Esses requisitos impõem desafios adicionais para a pesquisa e o desenvolvimento de algoritmos, que muitas vezes dependem de grandes volumes de dados clínicos para aprendizado.

Do ponto de vista regulatório, a Agência Nacional de Vigilância Sanitária (ANVISA) e a Food and Drug Administration (FDA) têm desenvolvido estruturas específicas para aprovação de softwares médicos baseados em IA. A FDA (2024) exige que os desenvolvedores apresentem evidências de desempenho

em múltiplos centros e garantam rastreabilidade completa do ciclo de vida do algoritmo, desde o treinamento até a atualização pós-mercado. Já a OMS (2021) recomenda que os países adotem sistemas de governança transparentes, com auditorias regulares e participação interdisciplinar, envolvendo especialistas em ética, direito e ciência de dados.

O conceito de IA explicável (Explainable AI, XAI) surge como resposta à necessidade de transparência. Diferentemente dos modelos de “caixa preta”, a XAI permite visualizar como o algoritmo chegou a determinada conclusão, exibindo os pixels ou regiões da imagem que mais influenciaram a decisão (The Lancet Digital Health, 2024). Essa transparência é crucial para aumentar a confiança dos profissionais e reduzir a resistência à adoção de novas tecnologias.

Outro ponto ético importante é a responsabilidade profissional. Quando ocorre um erro diagnóstico decorrente do uso de IA, surge a questão: quem é responsável — o desenvolvedor, o hospital ou o médico que supervisiona o sistema? A literatura jurídica e médica ainda debate essas fronteiras, mas há consenso de que o médico deve manter o papel decisório final, validando os resultados gerados pelo sistema (OMS, 2021; Radiology, 2025).

Por fim, destaca-se a importância da inclusão digital e da equidade tecnológica. A OMS (2021) e The Lancet Digital Health (2024) alertam que a implementação desigual da IA pode acentuar disparidades regionais, beneficiando apenas grandes centros urbanos com infraestrutura tecnológica avançada. Para que o uso da IA seja eticamente sustentável, é necessário investir em políticas públicas que ampliem o acesso, garantam interoperabilidade entre sistemas e promovam capacitação de profissionais de saúde em todo o território nacional (Cunha et al., 2023).

#### 4. CONCLUSÕES

A incorporação da Inteligência Artificial (IA) ao diagnóstico por imagem médica representa um dos marcos mais significativos da transformação digital na saúde

contemporânea. A literatura científica demonstra que as redes neurais convolucionais (CNNs), ao simularem o funcionamento do córtex visual humano, são capazes de extrair e reconhecer padrões de alta complexidade com precisão comparável — e, em muitos contextos, superior — à do especialista humano (Litjens et al., 2017; Esteva et al., 2019).

A radiologia, a tomografia e a ultrassonografia destacam-se como os campos de aplicação mais robustos, apresentando resultados consistentes na detecção de patologias, triagem automatizada e quantificação de achados clínicos. As evidências convergem no sentido de que a IA é capaz de alcançar acurácia diagnóstica média entre 90% e 97%, com ganhos expressivos em sensibilidade e especificidade (The Lancet Digital Health, 2024; Radiology, 2025). Esses resultados são especialmente relevantes em um contexto global de sobrecarga dos serviços de imagem e déficit de radiologistas em muitas regiões do mundo.

Mais do que uma simples ferramenta computacional, a IA constitui um novo paradigma assistencial, centrado em dados e sustentado por análises preditivas, integração de sistemas e apoio à decisão clínica. Ela amplia a capacidade humana de interpretar grandes volumes de informação, possibilitando diagnósticos mais rápidos, precisos e contextualizados (OMS, 2021). Ao mesmo tempo, reduz o tempo de emissão de laudos, otimiza fluxos operacionais e fortalece a segurança do paciente, consolidando-se como elemento estratégico da medicina baseada em evidências (FDA, 2024).

Contudo, a adoção da IA não elimina a necessidade da atuação humana, mas redefine o papel do especialista. O radiologista contemporâneo passa a ser um analista de dados clínicos e supervisor de sistemas inteligentes, responsável por validar, contextualizar e comunicar as interpretações automatizadas (Radiology, 2025). Essa relação simbiótica entre homem e máquina exige novas competências profissionais, como literacia digital, compreensão dos fundamentos algorítmicos e conhecimento das implicações éticas e legais do uso de IA na saúde (OMS, 2021).

Sob o ponto de vista ético, a IA traz benefícios inegáveis, mas também desafios. A transparência algorítmica (Explainable AI) torna-se essencial para preservar a confiança na prática médica, permitindo que profissionais compreendam e

justifiquem as decisões geradas pelos sistemas automatizados (The Lancet Digital Health, 2024). A governança de dados, por sua vez, deve garantir que as informações utilizadas no treinamento e na validação dos modelos respeitem os princípios de privacidade, segurança e equidade estabelecidos pela Lei Geral de Proteção de Dados Pessoais (LGPD – Lei nº 13.709/2018) (Brasil, 2018).

A Organização Mundial da Saúde (OMS, 2021) enfatiza que a ética da IA em saúde deve basear-se em cinco eixos: (1) promoção do bem-estar humano, (2) segurança e confiabilidade dos sistemas, (3) transparência e explicabilidade, (4) responsabilidade e prestação de contas, e (5) sustentabilidade e equidade global. Isso implica reconhecer que a tecnologia deve servir à humanidade — e não substituí-la.

O desafio maior, portanto, não é apenas desenvolver algoritmos mais precisos, mas integrá-los de forma ética, equitativa e sustentável aos sistemas de saúde, garantindo que seus benefícios sejam compartilhados por todos. Países de baixa e média renda, como o Brasil, enfrentam desafios adicionais de infraestrutura tecnológica, interoperabilidade e capacitação profissional (Cunha et al., 2023). Políticas públicas que promovam investimento em tecnologia da informação, criação de bases de dados locais e formação continuada de profissionais de saúde são fundamentais para garantir o uso seguro e eficiente da IA no diagnóstico por imagem.

Do ponto de vista científico, a IA abre horizontes inéditos para a medicina preditiva e personalizada. Algoritmos capazes de detectar padrões invisíveis ao olho humano podem antecipar desfechos clínicos e orientar decisões terapêuticas individualizadas (Nature Medicine, 2023). Esse avanço redefine o papel do diagnóstico por imagem, que passa de instrumento descritivo a componente ativo da gestão do cuidado e do prognóstico.

No entanto, é imprescindível reconhecer os limites epistemológicos da IA. Por mais sofisticado que seja o algoritmo, ele permanece dependente da qualidade dos dados de treinamento e da supervisão humana. A ausência de diversidade nos bancos de dados pode gerar vieses estruturais, reforçando desigualdades já existentes (OMS, 2021). Além disso, o uso acrítico de sistemas de “caixa

preta” compromete a transparência científica e o princípio da autonomia profissional.

Dessa forma, o futuro da medicina diagnóstica não será marcado pela substituição do especialista, mas pela colaboração inteligente entre humanos e máquinas, na qual a intuição clínica, a empatia e o julgamento ético se unem à velocidade e precisão dos algoritmos (The Lancet Digital Health, 2024; Radiology, 2025). Essa integração representa a essência da inteligência aumentada, conceito que propõe o uso ético e responsável da tecnologia para ampliar — e não suplantiar — a capacidade humana.

Em síntese, a IA já demonstrou ser uma ferramenta indispensável para o diagnóstico por imagem, com potencial de transformar a medicina contemporânea em uma prática mais precisa, eficiente e centrada no paciente. A consolidação de seu uso dependerá da convergência entre avanços tecnológicos, regulamentação responsável e compromisso ético com a equidade e a transparência. O verdadeiro sucesso da IA na medicina não será medido apenas pela acurácia de seus algoritmos, mas pela sua capacidade de gerar valor humano, clínico e social, promovendo uma saúde digital inclusiva, justa e sustentável para todos (OMS, 2021; Esteva et al., 2019; The Lancet Digital Health, 2024).

## REFERÊNCIAS

BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). Diário Oficial da União, Brasília, DF, 2018.

CUNHA, L. F.; ALMEIDA, J. R.; PIRES, R. T. Panorama da inteligência artificial em saúde no Brasil: desafios e perspectivas. *Revista Brasileira de Informática em Saúde*, v. 29, n. 1, p. 22–41, 2023.

ESTEVA, A. et al. A guide to deep learning in healthcare. *Nature Medicine*, v. 25, n. 1, p. 24–29, 2019.

FDA. Artificial Intelligence and Machine Learning in Medical Imaging. U.S. Food and Drug Administration, Washington, 2024.

GUYATT, G. H. et al. GRADE: An emerging consensus on rating quality of evidence and strength of recommendations. *BMJ*, v. 336, n. 7650, p. 924–926, 2011.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015.

LITJENS, G. et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*, v. 42, p. 60–88, 2017.

LUNDERVOLD, A. S.; LUNDERVOLD, A. An overview of deep learning in medical imaging focusing on MRI. *Zeitschrift für Medizinische Physik*, v. 29, n. 2, p. 102–127, 2019.

NATURE BIOMEDICAL ENGINEERING. AI in diagnostic ultrasound. *Nature Biomedical Engineering*, v. 7, n. 4, p. 322–331, 2023.

NATURE MEDICINE. Artificial intelligence in cardiovascular imaging. *Nature Medicine*, v. 29, n. 3, p. 415–430, 2023.

OMS. Ethics and governance of artificial intelligence for health: WHO guidance. Geneva: Organização Mundial da Saúde, 2021.

RADIOL. Artificial Intelligence in Diagnostic Imaging: 2025 Review. *Radiology*, v. 308, n. 2, p. 178–193, 2025.

RUSSELL, S.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. 4. ed. New Jersey: Pearson, 2021.

SHEN, D.; WU, G.; SUK, H. I. Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, v. 19, p. 221–248, 2017.

STANFORD AIM. AI in Emergency Radiology: Workflow Optimization and Clinical Impact. Stanford Artificial Intelligence in Medicine Laboratory, 2023.

THE LANCET DIGITAL HEALTH. Artificial intelligence in medical imaging: advances and regulation. *The Lancet Digital Health*, v. 6, n. 3, p. e210–e229, 2024.

WHITTEMORE, R.; KNAFL, K. The integrative review: updated methodology. *Journal of Advanced Nursing*, v. 52, n. 5, p. 546–553, 2005.

YASAKA, K.; ABE, O. Deep learning and artificial intelligence in radiology: current applications and future directions. *PLoS Medicine*, v. 15, n. 11, e1002707, 2018.

Palavras-chave: aprendizado profundo; inteligência artificial; radiologia; redes neurais; tomografia computadorizada; ultrassonografia.