



UNIRIO - Universidade Federal do Estado do Rio de Janeiro

Centro de Ciências Biológicas e da Saúde (CCBS)

Escola de Medicina e Cirurgia (EMC)

DANIEL NASCIMENTO MENDES

**IMPACTOS DA INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO E CLASSIFICAÇÃO
DOS NÓDULOS PULMONARES À TOMOGRAFIA COMPUTADORIZADA**

**RIO DE JANEIRO
2024**

DANIEL NASCIMENTO MENDES

**IMPACTOS DA INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO E CLASSIFICAÇÃO
DOS NÓDULOS PULMONARES À TOMOGRAFIA COMPUTADORIZADA**

Trabalho de Conclusão do Curso apresentado como requisito parcial
para obtenção do grau de médico no Curso de Medicina da Universidade
Federal do Estado do Rio de Janeiro - UNIRIO.

Orientadora: Ana Célia Baptista Koifman

**RIO DE JANEIRO
2024**

DANIEL NASCIMENTO MENDES

**IMPACTOS DA INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO E CLASSIFICAÇÃO
DOS NÓDULOS PULMONARES À TOMOGRAFIA COMPUTADORIZADA**

Trabalho de Conclusão do Curso apresentado como requisito parcial para obtenção do grau de médico no Curso de Medicina da Universidade Federal do Estado do Rio de Janeiro – UNIRIO e aprovado pela banca examinadora

Rio de Janeiro, 23 de julho de 2024

BANCA EXAMINADORA

Maria Ribeiro Santos Morard, Doutorado, UNIRIO

Márcia Lyrio Sindorf, Mestrado, UNIRIO

Maurício Ribeiro Borges, Mestrado, UNIRIO

AGRADECIMENTOS

Aos que tornaram essa jornada possível,

Quero expressar meus sinceros agradecimentos às pessoas que estiveram ao meu lado ao longo dessa caminhada. Minha família, com seu amor incondicional e apoio constante, foi a base sólida que sustentou cada passo que dei. Sou imensamente grato a cada um de vocês que acreditaram em mim, celebraram minhas conquistas e me impulsionaram a seguir em frente.

À memória daqueles que já partiram, mas cujas lições e amor ainda iluminam meu caminho, meu eterno reconhecimento. Em especial, à minha avó, cuja sabedoria e carinho deixaram uma marca permanente em meu coração, inspirando-me a perseguir meus sonhos com perseverança e compaixão.

A cada paciente que cruzou meu caminho durante esta jornada acadêmica, meu coração se enche de gratidão. Suas histórias, desafios e sorrisos foram verdadeiras lições de humanidade, recordando-me constantemente o privilégio e a responsabilidade de servir à saúde daqueles que confiaram em mim.

Aos mestres e colegas, cujo orientação, apoio e colaboração foram essenciais para o meu crescimento pessoal e profissional, meu sincero agradecimento. Seus conhecimentos, experiências e generosidade moldaram meu percurso acadêmico, tornando-me não apenas um médico, mas um agente de transformação na vida daqueles que precisam.

Por fim, agradeço a todos os que, de uma forma ou de outra, contribuíram para esta jornada. Que este trabalho possa ser uma pequena expressão de minha gratidão e compromisso com a medicina, e que possa, de alguma maneira, contribuir para o progresso e a saúde daqueles que cruzarem meu caminho no futuro.

Com sincera gratidão,

Daniel Nascimento.

Mendes DN. **Impactos da Inteligência Artificial na Detecção e Classificação dos nódulos pulmonares à tomografia computadorizada** [Trabalho de Conclusão de Curso]. Rio de Janeiro: Hospital Universitário Gaffrée e Guinle, Universidade Federal do Estado do Rio de Janeiro; 2024. 32 p.

RESUMO

INTRODUÇÃO: A inteligência artificial (IA) tem promovido transformações significativas em diversos campos da medicina, com destaque para a radiologia, em que técnicas de *deep learning* (DL) têm solucionado desafios complexos e aprimorado o desempenho clínico. O objetivo dessa revisão de literatura foi explorar os impactos da IA na prática médica em relação à capacidade de detecção e classificação de nódulos pulmonares. Com o advento de grandes bancos de dados, como o *Lung Image Database Consortium* (LIDC), as diversas arquiteturas de IA conseguem reconhecer padrões complexos e categorizá-los com exímia precisão. **MÉTODO:** Foi realizada uma revisão integrativa da literatura, abrangendo artigos publicados nos últimos cinco anos nas principais bases de dados da área da saúde. Após a eliminação de duplicatas, foram coletadas e compiladas informações pertinentes dos artigos selecionados para análise. **DISCUSSÃO:** Os resultados dos artigos analisados indicam um aumento considerável na precisão diagnóstica e uma redução de falsos negativos, além de otimização do tempo de trabalho dos profissionais da radiologia. A combinação do uso da IA com a expertise dos radiologistas mostrou-se uma alternativa eficaz para elevar a performance e a precisão diagnóstica. Observou-se aumento estatisticamente significativo na sensibilidade diagnóstica, especialmente para nódulos com menos de 20mm, com o auxílio da inteligência artificial. É relevante notar que os principais benefícios da aplicação da IA foram observados entre profissionais menos experientes, destacando seu papel como ferramenta de suporte e aprimoramento. **CONCLUSÕES:** A incorporação da IA na radiologia torácica representa um avanço substancial no diagnóstico de nódulos pulmonares. Embora a tecnologia não substitua o papel do radiologista, pode atuar como poderoso complemento, melhorando a acurácia e a eficiência do diagnóstico, além de potencialmente aumentar as taxas de sobrevida do paciente ao permitir intervenções mais precoces. Para maximizar os benefícios, é essencial continuar investindo em pesquisa e desenvolvimento de infraestrutura tecnológica. A aceitação e adesão pelos profissionais de saúde são fundamentais para a integração bem-sucedida dessa tecnologia na prática clínica.

Palavras-chave: Inteligência artificial. Nódulos pulmonares. Deep Learning. Tomografia computadorizada.

Mendes DN. *Impacts of Artificial Intelligence on the Detection and Classification of Pulmonary Nodules in Computed Tomography* [Final Paper]. Rio de Janeiro: Gaffrée and Guinle University Hospital, Federal University of the State of Rio de Janeiro; 2024. 32 p.

ABSTRACT

INTRODUCTION: Artificial intelligence (AI) has driven significant transformations across various fields of medicine, particularly in radiology, where deep learning (DL) techniques have solved complex challenges and enhanced clinical performance. This literature review aims to explore the impacts of AI in medical practice, primarily focusing on the detection and classification of pulmonary nodules. With the advent of large databases such as the Lung Image Database Consortium (LIDC), various AI architectures can recognize and categorize complex patterns with exceptional precision. **METHOD:** An integrative literature review was conducted, covering articles published in the past five years from the major health-related databases. After eliminating duplicates, pertinent information from the selected articles was collected and compiled for analysis (Table 1). **DISCUSSION:** The results from the analyzed articles indicate a considerable increase in diagnostic accuracy and a reduction in false negatives, as well as an optimization of the radiology professionals' workflow. The combination of AI usage with radiologists' expertise proved to be an effective alternative for enhancing diagnostic performance and accuracy. There was a significant increase in diagnostic sensitivity, especially for nodules smaller than 20mm, with the aid of artificial intelligence. Notably, the primary benefits of AI application were observed among less experienced professionals, highlighting its role as a supportive and enhancing tool. **CONCLUSIONS:** The incorporation of AI in thoracic radiology represents a substantial advancement in the diagnosis of pulmonary nodules. Although the technology does not replace the radiologist's role, it acts as a powerful complement, improving diagnostic accuracy and efficiency, and potentially increasing survival rates by enabling earlier interventions. To maximize these benefits, it is essential to continue investing in research and the development of technological infrastructure. Moreover, the acceptance and adoption by healthcare professionals are crucial for the successful integration of this technology into clinical practice.

Keywords: Artificial intelligence. Pulmonary Nodules. Deep Learning. Computed Tomography

LISTA DE TABELAS

Tabela 1 - IA na detecção de nódulos pulmonares.....	18
Tabela 2 - IA na classificação de nódulos pulmonares.....	22
Tabela 3 - IA na detecção e classificação de nódulos pulmonares.....	25

LISTA DE ABREVIATURAS E SIGLAS

AUC – Area Under the ROC Curve

CNN – Convolutional neural network

DL – Deep Learning

IA – Inteligência Artificial

IDRI – Image Database Resource Initiative

LIDC – Lung Image Database Consortium

LILACS – Literatura Latino-Americana e do Caribe em Ciências da Saúde

MEDLINE – Medical Literature Analysis and Retrieval System Online

ML – Machine Learning

NPS – Nódulo Pulmonar Sólido

PUBMED – National Library of Medicine

ROC – Receiver Operating Characteristic

SciELO – Scientific Eletronic Online

TC – Tomografia Computadorizada

WOS – Web of Science

SUMÁRIO

1. INTRODUÇÃO	9
2. METODOLOGIA	11
3. DISCUSSÃO	12
3.1. NÓDULOS PULMONARES	12
3.2. MECANISMOS DE IA	13
3.3. IA NA DETECÇÃO DE NÓDULOS PULMONARES	15
3.4. IA NA CLASSIFICAÇÃO DE NÓDULOS PULMONARES	18
3.5. IA NA DETECÇÃO E CLASSIFICAÇÃO DE NÓDULOS PULMONARES.....	22
4. CONCLUSÕES	25
REFERÊNCIAS	28

1. INTRODUÇÃO


A inteligência artificial (IA) é tema de interesse no campo da radiologia há aproximadamente seis décadas. Este conceito refere-se ao aprendizado de programas de computador que através da leitura de dados, executam tarefas que assimilam as funções cognitivas e a inteligência humana ⁽¹⁾. Na radiologia atual, os médicos são treinados para avaliar imagens e relatar achados, detectando, caracterizando e monitorando anormalidades, um processo dependente da expertise do profissional e por vezes subjetivo. Em contraste, a IA se destaca pelo reconhecimento de padrões complexos, utilizando conjuntos de imagens para fornecer uma avaliação quantitativa e automatizada ⁽²⁾.

Os sistemas técnicos de IA podem ser categorizados em quatro módulos principais ⁽³⁾: 1. Processamento de linguagem natural: responsável por abranger a habilidade dos sistemas de compreender e gerar linguagem humana; 2. Reconhecimento de imagens: que focaliza na capacidade de identificar e processar imagens visuais; 3. Interação humano-computador: habilidade fundamentada na comunicação entre humanos e máquina; 4. *Machine Learning* (ML) ou “Aprendizado de Máquina”: que capacita os sistemas a melhorarem seu próprio desempenho com base em dados acumulados. De forma mais específica, a associação da IA com a radiologia baseia-se em dois pilares principais: o *Deep Learning* (DL) ou “Aprendizado Profundo” e a disponibilidade de grandes bancos de dados de imagens. O DL, um subcampo da IA, é caracterizado pela utilização de algoritmos alimentados com dados que desenvolvem suas próprias inferências, isto é, sem interferência humana como as Redes Neurais Convolucionais (CNNs), amplamente empregadas em tarefas de reconhecimento de padrões de imagem ⁽⁴⁾. A disponibilidade de extensos bancos de dados, como o Lung Image Database Consortium (LIDC) e o Image Database Resource Initiative (IDRI), tem sido fundamental para o aprimoramento dos sistemas de DL, especialmente no contexto de imagens de nódulos pulmonares em tomografias computadorizadas (TC) ⁽⁵⁾.

Na literatura recente, a aplicação da IA na radiologia torácica tem sido amplamente explorada. Um exemplo disso é a exponencial crescente de artigos científicos dos últimos 5 anos (figura 1). Somente na National Library of Medicine (PubMed), mais de 700 artigos citam, pelo menos, “inteligência artificial” e “nódulos

pulmonares”. O avanço do DL no diagnóstico de nódulos pulmonares emergiu como um esquema alternativo promissor de suporte à decisão médica, contribuindo para a detecção de nódulos e classificação de malignidade ⁽⁶⁾. Além disso, é pertinente ressaltar que, em tomografias computadorizadas dos pulmões, nódulos suspeitos, que exigem qualquer forma de acompanhamento podem ser negligenciados ou interpretados de forma equivocada pelos radiologistas, resultando num diagnóstico e tratamento tardios. No Brasil, o câncer de pulmão é a principal causa de mortalidade entre os homens e a segunda entre as mulheres ⁽⁷⁾. No mundo, o câncer de pulmão figura como a principal etiologia de óbitos associados a câncer globalmente, tanto em homens quanto em mulheres ⁽⁸⁾. Portanto, a detecção precoce e a sistematização objetiva na classificação das lesões são cruciais para aumentar as taxas de sobrevida, uma vez que o tratamento precoce está diretamente relacionado a um prognóstico mais favorável ⁽⁹⁾.

Gráfico 1 - Comparação do número de artigos indexados pelo PubMed a cada ano mencionando os termos de busca “artificial intelligence” e “lung nodules”



Na prática médica a TC de tórax é indispensável na triagem e diagnóstico de nódulos pulmonares, devido acurácia alta deste método. No entanto, a identificação desses nódulos é uma tarefa complexa e lesões pequenas, especialmente as lesões com densidade próxima ao do parênquima pulmonar, podem não ser visualizadas.

Em resumo, a integração da IA na radiologia, particularmente na detecção e caracterização de nódulos pulmonares, revela-se promissora, contribuindo para diagnósticos mais precisos e tratamentos mais eficazes. Este artigo de revisão de literatura objetiva elucidar o impacto da IA e sua aplicação na detecção e classificação de nódulos pulmonares, tanto de forma objetiva, quanto subjetiva. Em segundo plano, delineamos algumas questões e desafios que persistem na incorporação desse avanço à prática clínica rotineira. Por fim, ressaltamos que a literatura apresentada neste estudo foi coletada de diversas fontes, principalmente do PubMed, com o material extraído primordialmente das seções "Discussão" e/ou "Limitações" de artigos indexados.

2. METODOLOGIA

Revisão integrativa da literatura, reunindo e sintetizando resultados de pesquisas experimentais e não experimentais sobre o tema. Primeiramente, foi realizada uma busca na literatura por meio do levantamento de produções científicas publicadas no período de 2019 a 2023, nas principais bases de dados da área da saúde: Medical Literature Analysis and Retrieval System Online (MEDLINE), Literatura Latino-Americana e do Caribe em Ciências da Saúde (LILACS), National Library of Medicine (PUBMED), Web of Science (WOS), Biblioteca Virtual em Saúde e no diretório de revistas Scientific Eletronic Library Online (SciELO).

Realizamos uma pesquisa na literatura no período de dezembro de 2023 e março de 2024 com base nos descritores "inteligência artificial", "*deep learning*", "*machine learning*" e "lung nodules", e focando em estratégia de busca avançada com auxílio do operador booleano "AND" e "OR" para combinar os descritores entre si. Foram removidos os artigos duplicados entre as bases. Após análise dos títulos, foram selecionados 189 artigos, seguida pela leitura dos resumos, totalizando 79 trabalhos. Por conseguinte, foi realizada a leitura dos textos completos, resultando em 10 trabalhos, sendo excluídos, em cada etapa, os artigos que não contemplaram os critérios de adequação ao tema. Foram coletados os dados referentes a título do artigo, autores, país, ano de publicação, delineamento do estudo, amostra, resultados e conclusões. Os dados foram organizados em uma planilha MS-Excel para análise e

avaliação descritiva dos estudos e resultados encontrados. Essa revisão não foi conduzida de forma sistemática.

3. DISCUSSÃO

3.1 NÓDULOS PULMONARES

Os nódulos pulmonares são lesões frequentemente identificadas em tomografias computadorizadas de tórax, representando um desafio diagnóstico. Grande parte desses nódulos não possuem caráter maligno, sendo achados de irrelevância clínica ⁽¹⁰⁾. Em 1984, a Sociedade Fleischner publicou um glossário de termos para radiologia torácica, definindo nódulo pulmonar como "qualquer lesão pulmonar ou pleural representada em uma radiografia por uma opacidade nitidamente definida, discreta e quase circular com 2-30 mm de diâmetro". Doze anos depois, a sociedade revisou esta definição, caracterizando o nódulo pulmonar como "opacidade redonda, moderadamente bem marginada e com no máximo 3 cm de diâmetro" ⁽¹¹⁾. Além disso, o nódulo pulmonar sólido (NPS) é descrito como uma opacidade radiológica com diâmetro de até 30mm, com pelo menos dois terços de suas margens circundadas pelo parênquima pulmonar ⁽¹²⁾. Os NPS podem ser classificados em quatro tipos ⁽¹³⁾: (a) bem circunscrito: o nódulo está localizado centralmente no pulmão sem conexões significativas com a vasculatura; (b) vascularizado: o nódulo está localizado centralmente no pulmão, mas possui significativa vascularização (conexões com vasos vizinhos); (c) cauda pleural: o nódulo está próximo à superfície pleural, conectado por uma estrutura fina chamada "cauda pleural"; e (d) justapleural: uma




Figura 1 - (a) Nódulo bem circunscrito. (b) Nódulo justavascular. (c) Nódulo com "cauda pleural". (d) Nódulo justapleural

proporção significativa da periferia do nódulo está conectada à superfície pleural (figura 1) ⁽¹⁴⁾. Lesões com diâmetro superior a 30mm são denominadas massas pulmonares, sendo geralmente de caráter maligno ⁽¹⁵⁾.

O câncer de pulmão é uma das neoplasias mais prevalentes e representa a principal causa de mortalidade por câncer ao nível mundial ⁽¹⁶⁾. Frequentemente, o carcinoma pulmonar é identificado em estágios avançados, pois os sintomas geralmente manifestam-se apenas quando a doença já progrediu significativamente. Sabe-se que a taxa de sobrevivência do câncer melhora consideravelmente quando esse tipo de neoplasia é diagnosticada de forma precoce ⁽¹⁷⁾. Evidências consistentes indicam que o rastreamento por TC pode reduzir a mortalidade em populações de alto risco, entretanto a implementação desses programas de triagem na prática clínica tem ocorrido de forma lenta ⁽¹⁸⁾. Consequentemente, o carcinoma pulmonar em estágio inicial pode ser diagnosticado somente após a detecção incidental de nódulos em tomografias de tórax solicitadas por outras hipóteses médicas ⁽¹⁹⁾. Da mesma forma, metástases pulmonares de origem extratorácica podem ser detectadas como nódulos incidentais e devem ser diagnosticadas e tratadas precocemente, considerando a alta probabilidade de disseminação tumoral adicional. Apesar da alta sensibilidade na detecção de nódulos pulmonares, a especificidade da TC de tórax para o diagnóstico de câncer de pulmão permanece insatisfatória. Além disso, a interpretação humana das imagens torácicas mostra-se subjetiva e com alta variabilidade interpessoal de leitura para detecção e classificação de nódulos pulmonares ⁽²⁰⁻²¹⁾.

3.2 MECANISMOS DE INTELIGÊNCIA ARTIFICIAL

O uso da IA pode ser uma nova abordagem para otimizar as lacunas existentes na detecção e classificação de nódulos pulmonares. Ao contrário do que se imagina, a IA é um termo amplo e que foi descrito por John McCarthy na década de 1950 ⁽²²⁾. Hoje, não é consensual a definição de IA, mas pode ser caracterizada como uma abordagem de utilização de computadores e tecnologias para simular comportamento humano, bem como pensamento crítico e inteligente ⁽²³⁾. Inicialmente, os algoritmos de IA destinados à análise de dados simples, eram codificados manualmente por programadores e não reconheciam padrões não programados especificamente. Então, surgiu o *Machine Learning*, uma subárea da IA, onde algoritmos podem reconhecer e aprender padrões dentro de conjuntos de dados

complexos para fazer previsões inteligentes, ao invés de seguir uma programação pré-estabelecida ⁽²⁴⁾. Contudo, os algoritmos tradicionais de ML ainda requerem intervenção humana considerável, e os padrões que podem avaliar são relativamente simples. Por fim, a ascensão da IA na radiologia tem forte influência do crescimento do *deep learning*, uma outra subárea de tecnologia. Diferente das abordagens tradicionais de ML, que exigem a extração manual de características e a estruturação dos dados por humanos, os algoritmos de DL trabalham com dados brutos e desenvolvem suas próprias representações para o reconhecimento de padrões ⁽²⁵⁾. Impulsionada pelo aumento do poder computacional, aliado ao advento de uma poderosa unidade de processamento gráfico, a DL é atualmente o método de escolha para análise de imagens radiológicas. Dentro do DL, ainda existe a Rede Neural Convolucional que é a arquitetura dominante para análise de imagens médicas ⁽²⁶⁾. Uma CNN é construída com várias camadas de convoluções que processam as




Figura 2 - Diagrama de Euler esquematizando a hierarquia da IA.
Fonte: Acervo pessoal.

imagens sequencialmente, de modo que a representação de uma camada (a primeira sendo a entrada de dados brutos) é alimentada na próxima camada e transformada em uma representação e, conseqüentemente, as características importantes sejam extraídas e interpretadas. A figura acima (figura 2) representa de forma esquemática os subcampos da IA.

3.3 IA NA DETECÇÃO DE NÓDULOS PULMONARES

Utilizando uma fusão de CNNs, Gürsoy et al.²⁷ compararam a performance de um modelo de IA com a avaliação de dois radiologistas experientes (>10 anos em radiologia torácica) na estimativa do risco de malignidade em nódulos pulmonares. Neste estudo, utilizou-se a análise da curva ROC (*receiver-operating characteristic*) para avaliar a acurácia, a sensibilidade e a especificidade da probabilidade de malignidade determinada pela IA e pela avaliação RADS dos radiologistas na classificação dos nódulos. A área sob a curva ROC (AUC) foi apresentada com seu respectivo erro padrão. Além disso, o estudo envolveu a análise retrospectiva de prontuários médicos de pacientes diagnosticados radiologicamente com nódulos pulmonares de diâmetro médio ≤ 3 cm e comprovados em histopatologia, o padrão ouro adotado. Foram selecionados 158 nódulos diagnosticados em 158 pacientes, sendo 81 benignos e 77 malignos. Os nódulos benignos foram assim classificados com base em características morfológicas na TC e mantiveram estabilidade radiológica por mais de cinco anos. Os nódulos malignos desse estudo foram provenientes de 77 pacientes que passaram por cirurgia e foram confirmados por histopatologia: adenocarcinomas (n=49), carcinoma de células escamosas (n=18), carcinoides pulmonares (n=6), carcinoma de células grandes (n=3) e carcinoma de células fusiformes (n=1). Apesar de evidenciar alta sensibilidade, estimada em 92.2% (IC 95%: 84–96%), os resultados do estudo indicaram que os radiologistas tiveram um desempenho superior ao do modelo de IA. A AUC para os radiologistas 1 e 2 foi de $0,917 \pm 0.023$ ($p < 0.001$) e $0,870 \pm 0.033$ ($p < 0.001$), respectivamente, enquanto a IA apresentou um AUC de $0,790 \pm 0.037$ ($p < 0.001$). O estudo ainda revelou, como desfecho secundário, que características morfológicas como “contorno espiculado”, “retração pleural” e presença de “pseudocavitação” foram mais frequentes em nódulos malignos, sendo esses achados estatisticamente significativos ($p < 0,001$). Além

disso, dos 158 nódulos avaliados, 11,3% (n=18) não foram detectados pela IA, o que reflete na sua especificidade de 58,7%. Os motivos para essa não detecção incluem a complexidade de alguns nódulos, a presença de artefatos ou baixa qualidade nas imagens de tomografia, e limitações no algoritmo da IA, que pode não ter sido treinado para reconhecer todos os tipos de nódulos, especialmente aqueles menores ou com padrões atípicos.

Em contrapartida, Blanc et al.²⁸ evidenciaram valores mais promissores de especificidade 86% (CI 95: 82%–92%) em seu algoritmo (SVM – *Support vector machine*) na detecção de nódulos pulmonares. Diferentemente de Gürsoy et al.²⁷, o estudo realizado na França utilizou a técnica de ML com um conjunto de dados que incluía 1056 imagens, cujo objetivo principal era detectar nódulos com volume maior ou menor que 100mm³. Nódulos menores são frequentemente considerados de menor risco de malignidade e diretrizes recentes sugerem que nódulos menores que 6mm (aproximadamente 100mm³) têm um risco muito baixo de malignidade⁽²⁹⁾. Após algumas etapas de pré-processamento, o algoritmo SVM mostrou-se útil na detecção dos nódulos patológicos com uma AUC de 0,9058 (IC 95%: 0.8746–0.9362), sensibilidade de 89% (CI 95: 84.83%–91.03%) e uma acurácia geral de 87% (CI 95: 84.83%–91.03%).

O estudo realizado por Cui et al.³⁰, um dos artigos com a maior quantidade de nódulos avaliados dessa revisão de literatura (n=1265), também foi responsável por desenvolver e avaliar um algoritmo de DL com uma arquitetura baseada numa CNN chamada *ResNet* composta de 50 camadas convolucionais. A análise retrospectiva utilizou um grande conjunto de dados de 39.014 casos de TC de tórax coletados em três hospitais chineses, no qual 38.414 casos foram usados para treinar os parâmetros do algoritmo e 600 casos para avaliar o desempenho diagnóstico do modelo. O padrão de referência diagnóstica para o conjunto de validação contou com três especialistas com mais de 20 anos de experiência em radiologia torácica, recrutados para avaliar independentemente as imagens, sendo o padrão estabelecido em pelo menos 2/3 de concordância entre os especialistas. Adicionalmente, nove médicos radiologistas revisores foram recrutados para avaliarem o conjunto de validação, incluindo cinco com mais de 10 anos de experiência e quatro radiologistas mais jovens (com mais de 5 anos de experiência). Todos os resultados de

classificação foram comparados ao padrão de referência, e as métricas diagnósticas foram obtidas e avaliadas por índice AUC. O algoritmo *ResNet* desenvolvido mostrou-se eficaz na detecção de nódulos pulmonares, superando os radiologistas em termos de AUC 0.86 (IC 95%: 0.84–0.90) e especificidade 85% (IC 95%: 73-96%). Além disso, o tempo médio necessário para completar cada estudo foi significativamente menor ($p < 0,001$) para o algoritmo (0,08-0,09 minutos) em comparação aos radiologistas (1,71 minutos). Diferente de outros estudos, a sensibilidade apresentada da IA foi menor se comparada a dos radiologistas (73% [IC 95%: 63-86%] e 83% [IC 95%: 75-89%], respectivamente).

A avaliação conjunta e de forma simultânea entre IA e radiologistas foi avaliada por Hsu et al.³¹. O estudo investigou a eficácia e o tempo de leitura de diferentes abordagens, para dois grupos de radiologistas (jovens e experientes), utilizando um sistema de detecção assistida por computador com IA para a identificação de nódulos pulmonares em TCs. Os dados foram colhidos de forma retrospectiva, incluindo 150 conjuntos de imagens de TC, contendo um total de 340 nódulos pulmonares com diâmetro de até 10 mm. Os pacientes foram selecionados a partir de um banco eletrônico de dados e os critérios de inclusão abrangeram casos com nódulos pulmonares pequenos, que foram posteriormente confirmados como câncer de pulmão primário ou metastático ($n=65$), nódulos que permaneceram estáveis por pelo menos dois anos em exames de acompanhamento ($n=278$), e nódulos detectados incidentalmente em exames de rastreamento. O estudo desenvolvido em Taiwan excluiu pacientes com outros acometimentos pulmonares como fibrose pulmonar grave, bronquiectasias difusas, consolidações extensas, pneumotórax ou derrame pleural maciço, bem como pacientes com mais de 10 nódulos. O estudo comparou três modos de leitura para os dois grupos de leitores: leitura independente da IA, leitura com IA como segunda leitura (na qual a IA é aplicada após uma avaliação inicial sem assistência), e leitura simultânea com IA (onde a IA é aplicada desde o início da avaliação). Os resultados mostraram que a sensibilidade média dos leitores jovens sem IA foi de 52% ($p < 0,001$), aumentando para 79% com IA como segunda leitura ($p=0,242$) e para 77% com IA simultânea ($p < 0,001$). Para os leitores mais experientes, a sensibilidade média sem IA foi de 74% ($p < 0,001$), aumentando para 85% com IA como segunda leitura ($p = 0,500$) e para 84% com IA simultânea ($p < 0,001$). A AUC média também melhorou significativamente

($p < 0,001$) com o uso da IA, passando de 0.61 [IC 95%: 0.59, 0.64] sem IA para 0.79 [IC 95%: 0.77, 0.81] com IA como segunda leitura e 0.77 [IC 95%: 0.75, 0.80] com IA simultânea para leitores jovens, e de 0.81 [IC 95%: 0.78, 0.83] sem IA para 0.87 [IC 95%: 0.85, 0.89] com IA como segunda leitura e 0.86 [IC 95%: 0.84, 0.88] com IA simultânea para leitores experientes ($p < 0,001$). Ao comparar modos de leitura com IA na segunda leitura e na leitura simultânea, a média da AUC foi semelhante para ambos os leitores juniores e seniores e todos os leitores ($p > 0.05$). Além disso, o tempo de leitura foi significativamente reduzido com o uso da IA simultânea e os valores de especificidade de todas as análises não apresentaram relevância estatística. O tempo médio de leitura por caso foi de 156 ± 34 segundos sem IA, 197 ± 46 segundos com IA como segunda leitura, e 124 ± 25 segundos com IA simultânea ($p < 0.001$). Isso representa uma economia média de 32 segundos por caso em comparação com a leitura manual e de 73 segundos com a leitura com IA como segunda leitura. Esses resultados indicaram que a utilização da IA, especialmente no modo de leitura simultânea, pode aumentar significativamente a eficiência do fluxo de trabalho e melhorar o desempenho diagnóstico da detecção e classificação de nódulos pulmonares.

Autor, Ano	Metodologia e Amostra	Conclusões
Gürsoy et al. 2021	Estudo Transversal. Nódulos estudados: 158	Embora a IA ter alta sensibilidade, a taxa de falsos positivos e negativos foi alta, e seu desempenho geral foi inferior ao dos radiologistas.
Hsu et al. 2021	Estudo Retrospectivo Comparativo. Nódulos estudados: 340	O uso da IA, na leitura simultânea, melhora significativamente a detecção de nódulos pulmonares e reduz o tempo de leitura. O aumento da sensibilidade foi ainda maior no grupo de radiologista inexperientes.
Blanc et al. 2020	Estudo Transversal Retrospectivo. 1056 imagens estudadas	O estudo desenvolveu uma IA que alcançou uma AUC de 0.905, alta sensibilidade e especificidade. Destacando a importância de técnicas avançadas de ML na melhoria da detecção diagnóstica.
Cui et al. 2020	Estudo Transversal Retrospectivo. Nódulos estudados: 1265	O algoritmo IA foi eficaz na detecção de nódulos, com AUC e especificidade, superando os radiologistas. O tempo médio de análise foi significativamente menor para o algoritmo. No entanto, a sensibilidade da IA foi menor que a dos radiologistas.

Tabela 1 - IA na detecção de nódulos pulmonares. ML - Machine Learning. AUC - Área sob a curva ROC

3.4 IA NA CLASSIFICAÇÃO DE NÓDULOS PULMONARES

O estudo conduzido por Chen et al.³² avaliou retrospectivamente a eficácia de um algoritmo para a classificação de nódulos também utilizando uma arquitetura de CNN. A análise incluiu um total de 1.002 pacientes e obteve a maior quantidade de nódulos estudados desta revisão de literatura (n=5638). Foram excluídas imagens com artefatos significativos, imagens sem nódulos pulmonares e com outras alterações morfológicas além de nódulos pulmonares. O padrão de referência foi definido a partir da conclusão de quatro radiologistas experientes com mais de 10 anos de experiência e um radiologista-chefe com mais de 15 anos de experiência em radiologia torácica. As imagens foram inicialmente avaliadas manualmente por dois radiologistas em um modo de leitura dupla-cego, seguido pela avaliação da IA, que utilizou uma CNN de última geração para detectar e classificar os nódulos pulmonares. O algoritmo da IA apresentou uma sensibilidade de 90.19% (IC 95%: 89.39-90.96%), enquanto a avaliação humana obteve uma sensibilidade de 49.88% (IC 95%: 48.56-51.19%) ($p < 0.001$). Além disso, a taxa de nódulos falsos-positivos por caso para o sistema IA foi de 0.30 ± 0.84 , comparado com 0.24 ± 0.68 para a avaliação profissional, porém sem relevância estatística ($p = 0.12$). O diferencial desse estudo foi a demonstração dos resultados classificando por subgrupos de nódulos. Para nódulos com diâmetro $< 8\text{mm}$ e entre 8 e 15mm a sensibilidade da IA foi significativamente melhor (89,04% e 98,19% $p < 0,001$), comparada à classificação manual (52,53% e




Figura 3 - Imagens de nódulos falso-negativos, não detectados pela avaliação humana.

31,85% $p < 0,001$), enquanto para nódulos ≥ 15 mm, não houve diferença significativa entre IA e a detecção manual ($p=0.08$). A figura acima (figura 3) representa uma das imagens que incluíam nódulos sólidos (a) e nódulos em vidro fosco (b) que não foram classificados pelos radiologistas, mas detectados pela IA. Os resultados desse estudo indicaram que o sistema desenvolvido com IA foi significativamente mais sensível na detecção de nódulos pulmonares em comparação com a avaliação manual, especialmente para nódulos < 15 mm. O aumento na sensibilidade é crucial, pois a detecção precoce de nódulos pulmonares pode levar ao diagnóstico mais rápido e, consequentemente, a um tratamento mais eficaz ⁽³³⁾.

De forma semelhante, Chao et al.³⁴ conduziram um ensaio clínico que investigava a eficácia da detecção assistida por IA de nódulos pulmonares em tomografias de tórax. A intenção foi determinar se a assistência por IA poderia melhorar o desempenho diagnóstico e a precisão dos médicos ao classificar nódulos pulmonares. Para análise deste trabalho, foram incluídas 200 imagens de TC de tórax de pacientes com mais de 20 anos, com tamanho de nódulos variando de 4 a 32mm e com cortes de imagem < 3.0 mm de espessura. De forma análoga ao estudo anterior, Chao et al.³⁴ excluiu exames que apresentaram outras anormalidades como atelectasias, consolidações, imagens com tumorações > 30 mm e metástases pulmonares. Inicialmente, três especialistas (pneumologista, cirurgião torácico e radiologista) com 15 anos ou mais de experiência foram convocados para avaliar as imagens e determinar a presença de nódulos pulmonares, criando o padrão de referência. Posteriormente, oito médicos não radiologistas (separados em grupo A e B) avaliaram as imagens sem (grupo A) e com (grupo B) assistência da IA, a interpretação de cada leitor sobre a presença, localização e tamanho do nódulo foi registrada. Após um período de 4 semanas, os oito médicos trocaram de cenário e analisaram as imagens com auxílio ou não das anotações feitas pela IA, ou seja, o grupo A foi auxiliado pelo software de IA, e o grupo B não. A sensibilidade global na detecção de nódulos pulmonares aumentou de 67.7% sem assistência da IA para 88.4% com assistência da IA ($p < 0.001$), enquanto a AUC também obteve um aumento significativo de 0.831 para 0.910 com auxílio da IA. Semelhante a Chen et al.³², o estudo mostrou um aumento significativo na sensibilidade para nódulos menores (< 20 mm). O aumento mais expressivo foi para nódulos entre 4-5mm onde a sensibilidade aumentou de 39.3% para 80.3% com assistência de IA ($p=0.0003$). Além

disso, foi evidenciado que, para nódulos em vidro fosco a sensibilidade aumentou de 72.5% para 91% com assistência de IA destacando a capacidade de o software detectar nódulos difíceis de identificar. Como a assistência da IA melhorou substancialmente a sensibilidade na detecção de pequenos nódulos mostrando-se útil na utilização para verdadeiros positivos, foram analisadas, também, as taxas de especificidade, refletindo a exatidão da detecção dos verdadeiros negativos. Os resultados expuseram que a especificidade era menor para a detecção com assistência da IA, entretanto, a diferença não obteve significância estatística ($p>0,05$). Portanto, a IA conseguiu melhorar a sensibilidade sem comprometer significativamente a especificidade, sendo importante para evitar falsos positivos, levando a procedimentos desnecessários e aumentando a morbidade dos pacientes.

Enquanto alguns estudos excluía imagens sugestivas de metástases pulmonares, Hendrix et al.³⁵ objetivaram desenvolver e validar uma IA baseada em *Deep Learning* para classificar nódulos benignos, neoplasias primárias de pulmão e metástases pulmonares em exames de TC de tórax. Utilizando uma amostra total de 200 pacientes e 615 nódulos, foram selecionados apenas neoplasias malignas primárias de pulmão confirmadas histopatologicamente e menores que 30mm; os casos de metástases incluídos foram aqueles que apresentavam até 15 nódulos metastáticos; além disso foram excluídas imagens de pacientes com fibrose pulmonar extensa ou consolidações. Uma equipe de cinco radiologistas torácicos, com experiência variando de 2 a 21 anos, anotou e mediu de forma independente todos os nódulos pulmonares no conjunto de dados do teste. Dois radiologistas externos associaram as anotações feitas pela equipe ao diagnóstico de câncer, usando dados do Registro Nacional de Câncer dos Países Baixos. O desempenho geral da IA no estudo se mostrou importante apresentando uma sensibilidade para nódulos benignos de 94.3% (IC 95%: 88.1–98.8%), neoplasias primárias de pulmão de 96.9% (IC 95%: 91.7–100%) e metástases pulmonares de 92.0% (IC 95%: 88.5–95.5%). Na comparação com os radiologistas, o sistema de DL apresentou uma sensibilidade significativamente maior que a maioria (pelo menos três dos cinco radiologistas), principalmente para metástases, embora com uma taxa de falsos positivos ligeiramente maior (diferença média de 0.6 FP/s). Os falsos negativos foram categorizados principalmente como nódulos justapleurais, justavasculares e não sólidos. Os falsos positivos incluíram principalmente detecções duplicadas, lesões não

nodulares e fibroses. Além disso, para neoplasias primárias pulmonares não houve diferença significativa na sensibilidade entre a IA e os observadores humanos. Os resultados observados, compactuam com o fato de que o sistema de IA pode auxiliar radiologistas na prática clínica diária, melhorando a detecção de nódulos pulmonares e reduzindo a carga de trabalho.

Autor, Ano	Metodologia e Amostra	Conclusões
Chen et al. 2023	Estudo Transversal Retrospectivo. Nódulos estudados: 5638	A IA foi altamente eficaz na classificação com uma sensibilidade significativamente maior em comparação com radiologistas. A taxa de FP da IA foi ligeiramente superior ($p = 0,12$). A análise por tamanho mostrou significância para nódulos menores que 15mm.
Chao et al. 2023	Ensaio Clínico Retrospectivo. Nódulos estudados: 205	O uso da IA pode melhorar significativamente a precisão da classificação de nódulos pulmonares, especialmente para nódulos menores (4-5mm). A sensibilidade e AUC obtiveram aumentos significativos, inclusive para nódulos em vidro fosco. Nesse estudo, a especificidade diminuiu com o uso da IA ($p > 0,05$).
Hendrix et al. 2023	Estudo Transversal Retrospectivo. Nódulos estudados: 615	A IA evidenciou uma alta sensibilidade para classificar nódulos benignos, neoplasias primárias e MTX. Comparado a maioria dos radiologistas, a IA apresentou uma sensibilidade maior para MTX, embora com uma alta taxa de FP. Não houve relevância estatística na classificação de neoplasias primárias entre os grupos.

Tabela 2 - IA na classificação de nódulos pulmonares. FP - Falso Positivo. AUC - Área sob curva ROC
MTX - Metástases

3.5 IA NA DETECÇÃO E CLASSIFICAÇÃO DE NÓDULOS PULMONARES

Chae et al.³⁶ investigaram a aplicação de um modelo de DL para a detecção e classificação de pequenos nódulos pulmonares (<20mm) em imagens de TC de tórax. Foram incluídas imagens de TC de tórax com nódulos malignos (n=94) confirmados histopatologicamente e nódulos benignos (n=114) confirmados patologicamente ou que não apresentaram aumento de tamanho por mais de um ano. Foram excluídos nódulos <5mm e >20mm e pacientes com outras lesões pulmonares como consolidações ou tuberculose. Participaram deste estudo, oito revisores humanos, sendo: dois estudantes de medicina, dois residentes de radiologia, dois

médicos não radiologistas e dois radiologistas torácicos. O procedimento consistiu em duas rodas de avaliação das imagens, uma sem e outra com a predição de malignidade do algoritmo de IA. A sensibilidade aumentou principalmente nos grupos de estudantes (AUC aumentou de 0,68 para 0,80; $p < 0,05$) e médicos não radiologistas (AUC aumentou de 0,70 para 0,83; $p > 0,05$), indicando que o modelo foi particularmente útil para observadores com menos experiência, significativamente para o grupo dos estudantes. A AUC média dos radiologistas aumentou em 0.02, mostrando uma ligeira melhoria com a assistência do modelo, mas não estatisticamente significativa ($p > 0,05$).

O estudo realizado por Pan et al.³⁷ também foi conduzido com objetivo de avaliar a eficácia da IA na detecção e classificação de nódulos pulmonares em comparação com radiologistas experientes em exames de TC de tórax. Foram incluídos 360 nódulos nas avaliações com a predominância de nódulos malignos ($n=251$); utilizou-se resultados patológicos pós-operatórios como padrão ouro. Os resultados mostraram que a IA apresentou uma taxa de falso positivo significativamente maior (24,77% quando comparada a 4,59% dos radiologistas; $p < 0,001$) e uma taxa de verdadeiro negativo significativamente menor comparada à revisão manual (IA 75,23%; Radiologista 95,41%; $p < 0,001$). Além disso, apesar da IA obter uma acurácia tão alta quanto a dos radiologistas, 81,94% e 83,06% respectivamente, e uma taxa de falso negativo menor, tais valores não apresentaram relevância estatística ($p > 0,05$). Também foi exposto, por mais que esperado, que o tempo médio de leitura da IA foi significativamente menor se comparado a revisão manual ($p < 0,0001$), $195,4 \pm 65,2$ segundos e $581,1 \pm 116,8$ segundos, respectivamente. Essas análises reforçam o potencial da IA como uma ferramenta auxiliar no diagnóstico de nódulos pulmonares.

Du et al.³⁸ conduziu um estudo que avaliou o poder diagnóstico da IA na classificação de benignidade e malignidade comparando-a à uma equipe multidisciplinar de especialistas experientes (MDT). Este estudo retrospectivo incluiu 152 pacientes com um total de 194 nódulos pulmonares (171 malignos e 23 benignos), confirmados patologicamente no pós-operatório. Foram incluídos os pacientes com a presença de nódulos altamente suspeitos, onde não era possível descartar malignidade, sendo o tratamento cirúrgico necessário. Pacientes com histórico de

cirurgia torácica ou quimioterapia prévia ou lesões torácicas malignas confirmadas foram excluídos; além de lesões >30mm. A IA analisou as imagens de TC para identificar a localização, tamanho, volume, densidade e a probabilidade de malignidade dos nódulos pulmonares, considerando nódulos com probabilidade maior que 70% como malignos. Os médicos e a MDT, composta por especialistas dos departamentos de Cirurgia Torácica, Pneumologia e Radiologia, realizou uma avaliação conjunta baseando-se na situação clínica do paciente, exames complementares relevantes e suas implicações. Para quantificar e padronizar a acurácia diagnóstica de diferentes métodos isoladamente ao diagnóstico de nódulos pulmonares, foram analisadas as diferenças na AUC. Ao longo desse estudo, o coeficiente Kappa (k) foi usado para medir a concordância entre os métodos diagnósticos (IA, médicos e MDT) e os resultados patológicos pós-operatórios: um $k > 0,4$ representa concordância estatística. Os resultados demonstraram que o sistema de IA apresentou uma acurácia de 89,69%, sensibilidade de 92,98% e especificidade de 65,22 AUC de 0,768 ($p \leq 0,001$). Em comparação, a leitura manual por médicos teve uma acurácia de 85,57%, sensibilidade de 88,30%, especificidade de 65,22%, AUC de 0,791 ($p \leq 0,001$), com um índice $k = 0.437$. A análise pela MDT além de evidenciar uma concordância de diagnóstico quase perfeita ($k=0.852$), também mostrou a melhor performance diagnóstica, com acurácia de 96,91%, sensibilidade de 98,25%, especificidade de 86,96%, e AUC de 0,926 ($p \leq 0,001$). Um segundo desfecho, foi avaliar o tempo necessário para avaliação das imagens. IA reduziu significativamente o tempo médio de detecção de nódulos para 145 ± 97 segundos ($p \leq 0,001$), comparado a 534 ± 297 segundos para a leitura manual e 421 ± 128 segundos para MDT. Embora a IA tenha mostrado alta sensibilidade e resolutividade no tempo de detecção, a taxa de falso-positivos foi relativamente alta (FP = 34,78%), possivelmente devido à dificuldade de interpretar características implícitas e a diversidade e complexidade dos dados de treinamento. A IA pode confundir características benignas, como espessamento septal, calcificação da cartilagem, espessamento vascular, com nódulos malignos. Além disso, o desempenho da IA está diretamente relacionado à diversidade e qualidade dos dados de treinamento, e a falta de representatividade desses dados pode resultar em vieses. Erros na segmentação dos nódulos também contribuem para interpretações incorretas, aumentando a taxa de falsos positivos. Finalmente, a presença de outras doenças pulmonares ou alterações fisiológicas, bem como a variação na qualidade das imagens devido a diferentes equipamentos e

protocolos de imagem, impactam negativamente a precisão da IA destacando a necessidade de revisão clínica por especialistas para melhorar a precisão diagnóstica. Estes resultados indicaram que, enquanto a IA oferece uma melhoria significativa na detecção precoce e na eficiência do trabalho, uma abordagem multidisciplinar proporciona a maior precisão e confiabilidade, reforçando a importância da colaboração entre especialistas no diagnóstico de nódulos pulmonares. Dessa forma, a implementação de sistemas de IA em conjunto com abordagens multidisciplinares pode representar um avanço significativo na prática clínica, potencialmente melhorando a precisão diagnóstica, os desfechos dos pacientes e a eficiência dos serviços.

Autor, Ano	Metodologia e Amostra	Conclusões
Pan et al. 2023	Estudo Transversal Retrospectivo. Nódulos estudados: 360	Embora apresentando tempo de leitura menor ($p < 0,001$) os resultados demonstraram inferioridade da IA em relação aos radiologistas com uma maior taxa de FP e menor taxa de VN. Comparativamente, a acurácia não obteve valores significativo entre os grupos.
Du et al. 2022	Estudo Transversal Retrospectivo. Nódulos estudados: 194	A IA (AUC 0.768) demonstrou números superiores ao médicos (AUC 0.791) no que tange acurácia, sensibilidade, especificidade, FP e FN. Porém, comparativamente ao MDT (AUC 0.926), tais dados foram inferiores.
Chae et al. 2019	Estudo Transversal Retrospectivo. Nódulos estudados: 208	O modelo de DL desenvolvido no estudo, evidenciou melhora significativa quando utilizado pelo grupo de estudantes. Os demais grupos, não obtiveram valores significativos de melhora

Tabela 3 - IA na detecção e classificação de nódulos pulmonares. FP - Falso Positivo. FN - Falso Negativo. AUC - Área sob curva ROC. MDT - Equipe Multidisciplinar de Especialistas. DL - *Deep Learning*

4. CONCLUSÕES

A revisão integrativa realizada descreveu o impacto significativo da inteligência artificial na detecção e classificação de nódulos pulmonares por tomografia computadorizada. Os algoritmos de *Deep Learning*, especialmente as Redes Neurais Convolucionais Profundas, demonstraram uma precisão diagnóstica

superior, além de uma capacidade notável de reduzir falsos negativos, o que contribui para diagnósticos mais precoces e eficientes, como demonstrado por Gürsoy et al ⁽²⁷⁾. Esses avanços são particularmente importantes em um contexto clínico onde a precisão e a rapidez no diagnóstico podem impactar diretamente os desfechos dos pacientes.

A importância de bancos de dados amplos e detalhadamente anotados, como o Lung Image Database Consortium (LIDC) e o Image Database Resource Initiative (IDRI) ⁽³⁹⁾ fornecem uma base robusta para o desenvolvimento e aprimoramento dos sistemas de DL, permitindo que os algoritmos sejam treinados com uma vasta quantidade de imagens, o que facilita o reconhecimento de padrões complexos e melhora significativamente a detecção de nódulos pulmonares. A utilização de tais recursos é crucial para a criação de modelos que não apenas identifiquem nódulos, mas também diferenciem entre nódulos benignos e malignos com alta precisão, como mostrado por Hendrix et al ⁽³⁵⁾.

A aplicação da IA na radiologia torácica tem sido amplamente explorada nos últimos anos. O aumento exponencial na quantidade de pesquisas publicadas, reflete um interesse crescente na implementação dessa tecnologia na prática clínica ⁽⁴⁰⁾. Estudos como o de Hsu et al. ⁽³¹⁾ e Pan et al. ⁽³⁷⁾ evidenciaram que a IA pode atuar como um "segundo leitor", indicando que uma abordagem colaborativa pode proporcionar melhores resultados diagnósticos, além de melhorar a acurácia diagnóstica e diminuir significativamente a carga de trabalho dos radiologistas. Este avanço é particularmente importante, dado que a detecção precoce está diretamente associada a melhores prognósticos e maiores taxas de sobrevida ⁽⁴¹⁾.

No entanto, a implementação da IA na prática clínica ainda enfrenta desafios significativos. A literatura atual sugere que, embora a IA tenha o potencial de complementar e até melhorar a prática radiológica tradicional, sua implementação eficaz depende de um desenvolvimento cuidadoso e de uma infraestrutura tecnológica avançada. Além da variação na qualidade das imagens, as diferenças nos protocolos de aquisição de TC e a necessidade de grandes volumes de dados anotados para o treinamento dos algoritmos são barreiras que precisam ser superadas para garantir a consistência e a generalização dos modelos de IA ⁽⁴²⁾. Além disso, a ética e a proteção dos dados são preocupações fundamentais, uma vez que a utilização de dados

médicos sensíveis requer rigorosos controles de privacidade e segurança, além de que a aceitação e confiança dos profissionais de saúde e dos pacientes também são essenciais para a integração bem sucedida dessa tecnologia.

No contexto em que o câncer de pulmão é a principal causa de mortalidade por câncer no mundo ⁽¹⁶⁾, a incorporação da IA pode representar um avanço significativo no diagnóstico precoce e no tratamento dessa doença. A sobrecarga de trabalho dos radiologistas reforça a necessidade de soluções automatizadas que possam aliviar a carga destes e melhorar a eficiência do diagnóstico. Para que o uso da IA seja efetivamente integrado na prática clínica, é imperativo que se continue a investir em pesquisa e desenvolvimento, focando na padronização dos dados, no treinamento adequado dos profissionais e na criação de diretrizes éticas robustas. Somente assim poderemos assegurar que os avanços tecnológicos se traduzam em melhorias concretas na saúde dos pacientes.

A adoção da IA na radiologia torácica deve ser vista como uma evolução colaborativa, onde a tecnologia serve como um suporte valioso aos profissionais de saúde, impactando na detecção e classificação dos nódulos pulmonares, e consequentemente, melhorando os desfechos dos pacientes. A jornada para a plena integração da IA na radiologia ainda está em andamento, mas as evidências atuais são encorajadoras e apontam para um futuro em que a tecnologia e a medicina trabalham juntas para salvar vidas.

REFERÊNCIAS

1. Russel S, Norvig P. Artificial intelligence: A Modern approach. 4th ed. Prentice Hall; 2021.
2. Obermeyer Z, Emanuel EJ. Predicting the future — Big Data, Machine Learning, and Clinical Medicine. *N Engl J Med*. 2016;375(13):1216-1219.
3. Lv, Z., Poiesi, F., Dong, Q., Lloret, J., & Song, H. (2022). Deep Learning for Intelligent Human–Computer Interaction. *Appl Sci*. 2022;12(22):11457.
4. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436-444.
5. Armato SG 3rd, et al. The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): a completed reference database of lung nodules on CT scans. *Med Phys*. 2011;38(2):915-931.
6. Lao J, et al. A Deep Learning-Based Radiomics Model for Prediction of Survival in Glioblastoma Multiforme. *Sci Rep*. 2020;10(1):2166.
7. Instituto Nacional de Câncer (INCA). Estimativa 2023: Incidência de Câncer no Brasil. INCA; 2023.
8. Organização Mundial da Saúde. [Internet]. Disponível em: <http://www.who.int/en/>. Acessado em 20 de março de 2024.
9. Kadara H, Tran LM, Liu B, Vachani A, Li S, Sinjab A, et al. Early Diagnosis and Screening for Lung Cancer. *Cold Spring Harb Perspect Med*. 2021 Sep 1;11(9):a037994.
10. Jacob M, Romano J, Ara Jo D, Pereira JM, Ramos I, Hespanhol V. Predicting lung nodules malignancy. *Pulmonology*. 2022;28(6):454-60.
11. Travis WD, Brambilla E, Müller-Hermelink HK, Harris CC. Pathology and Genetics of Tumours of the Lung, Pleura, Thymus and Heart. Lyon: IARC Press; 2004.
12. Gould MK, Tang T, Liu IL, et al. Recent Trends in the Identification of Incidental Pulmonary Nodules. *Am J Respir Crit Care Med*. 2015;192(10):1208-1214.
13. MacMahon H, Naidich DP, Goo JM, et al. Guidelines for Management of Incidental Pulmonary Nodules Detected on CT Images: From the Fleischner Society 2017. *Radiology*. 2017;284(1):228-243.
14. Kostis WJ, Reeves AP, Yankelevitz DF, Henschke CI. Three-dimensional segmentation and growth-rate estimation of small pulmonary nodules in helical CT images. *IEEE Trans Med Imaging*. 2003 Oct;22(10):1259-74.

15. Halder A, Dey D, Sadhu AK. Lung Nodule Detection from Feature Engineering to Deep Learning in Thoracic CT Images: a Comprehensive Review. *J Digit Imaging*. 2020 Jun;33(3):655-77.
16. Sung H, Ferlay J, Siegel RL, Laversanne M, Soerjomataram I, Jemal A, et al. Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA Cancer J Clin*. 2021 May;71(3):209-49
17. Birring SS, Peake MD. Symptoms and the early diagnosis of lung cancer. *Thorax*. 2005 Apr;60(4):268-9.
18. de Koning HJ, van der Aalst CM, de Jong PA, Scholten ET, Nackaerts K, Heuvelmans MA, et al. Reduced Lung-Cancer Mortality with Volume CT Screening in a Randomized Trial. *N Engl J Med*. 2020 Feb 6;382(6):503-13.
19. Schmid-Bindert G, Vogel-Claussen J, Gütz S, Fink J, Hoffmann H, Eichhorn ME, et al. Incidental Pulmonary Nodules - What Do We Know in 2022. *Respiration*. 2022;101(11):1024-34.
20. Toyoda Y, Nakayama T, Kusunoki Y, Iso H, Suzuki T. Sensitivity and specificity of lung cancer screening using chest low-dose computed tomography. *Br J Cancer*. 2008 May 20;98(10):1602-7.
21. Singh S, Pinsky P, Fineberg NS, Gierada DS, Garg K, Sun Y, et al. Evaluation of reader variability in the interpretation of follow-up CT scans at lung cancer screening. *Radiology*. 2011 Apr;259(1):263-70.
22. McCarthy J, Minsky ML, Rochester N, Shannon CE. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AIMag* [Internet]. 2006 Dec.15 [cited 2024 jun.27];27(4):12. Disponível em: <https://ojs.aaai.org/aimagazine/index.php/aimagazine/article/view/1904>
23. Amisha, Malik P, Pathania M, Rathaur VK. Overview of artificial intelligence in medicine. *J Family Med Prim Care*. 2019 Jul;8(7):2328-2331. doi: 10.4103/jfmpc.jfmpc_440_19. PMID: 31463251; PMCID: PMC6691444.
24. Chartrand G, Cheng PM, Vorontsov E, Drozdal M, Turcotte S, Pal CJ, et al. Deep Learning: A Primer for Radiologists. *Radiographics*. 2017;37(7):2113-31.
25. Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, et al. A guide to deep learning in healthcare. *Nat Med*. 2019 Jan;25(1):24-9.

26. de Margerie-Mellon C, Chassagnon G. Artificial intelligence: A critical review of applications for lung nodule and lung cancer. *Diagn Interv Imaging*. 2023 Jan;104(1):11-7.
27. Gürsoy Çoruh A, Yenigün B, Uzun Ç, Kahya Y, Büyükceran EU, Elhan A, et al. A comparison of the fusion model of deep learning neural networks with human observation for lung nodule detection and classification. *Br J Radiol*. 2021 Jul 1;94(1123):20210222.
28. Blanc D, Racine V, Khalil A, Deloche M, Broyelle JA, Hammouamri I, et al. Artificial intelligence solution to classify pulmonary nodules on CT. *Diagn Interv Imaging*. 2020 Dec;101(12):803-10.
29. González Maldonado S, Delorme S, Hüsing A, Motsch E, Kauczor HU, Heussel CP, et al. Evaluation of Prediction Models for Identifying Malignancy in Pulmonary Nodules Detected via Low-Dose Computed Tomography. *JAMA Netw Open*. 2020 Feb 5;3(2):e1921221.
30. Cui S, Ming S, Lin Y, Chen F, Shen Q, Li H, et al. Development and clinical application of deep learning model for lung nodules screening on CT images. *Sci Rep*. 2020 Aug 12;10(1):13657.
31. Hsu HH, Ko KH, Chou YC, Wu YC, Chiu SH, Chang CK, et al. Performance and reading time of lung nodule identification on multidetector CT with or without an artificial intelligence-powered computer-aided detection system. *Clin Radiol*. 2021 Aug;76(8):626.e23-626.e32.
32. Chen J, Cao R, Jiao S, Dong Y, Wang Z, Zhu H, et al. Application value of a computer-aided diagnosis and management system for the detection of lung nodules. *Quant Imaging Med Surg*. 2023 Oct 1;13(10):6929-41.
33. Mazzone PJ, Lam L. Evaluating the Patient With a Pulmonary Nodule: A Review. *JAMA*. 2022 Jan 18;327(3):264-73.
34. Chao HS, Tsai CY, Chou CW, Shiao TH, Huang HC, Chen KC, et al. Artificial Intelligence Assisted Computational Tomographic Detection of Lung Nodules for Prognostic Cancer Examination: A Large-Scale Clinical Trial. *Biomedicines*. 2023 Jan 6;11(1):147.
35. Hendrix W, Hendrix N, Scholten ET, Mourits M, Trap-de Jong J, Schalekamp S, et al. Deep learning for the detection of benign and malignant pulmonary nodules in non-screening chest CT scans. *Commun Med (Lond)*. 2023 Oct 27;3(1):156.

36. Chae KJ, Jin GY, Ko SB, Wang Y, Zhang H, Choi EJ, et al. Deep Learning for the Classification of Small (≤ 2 cm) Pulmonary Nodules on CT Imaging: A Preliminary Study. *Acad Radiol*. 2020 Apr;27(4):e55-e63.
37. Pan W, Fang X, Zang Z, Chi B, Wei X, Li C. Diagnostic efficiency of artificial intelligence for pulmonary nodules based on CT scans. *Am J Transl Res*. 2023;15(5):3318-25.
38. Du W, He B, Luo X, Chen M. Diagnostic Value of Artificial Intelligence Based on CT Image in Benign and Malignant Pulmonary Nodules. *J Oncol*. 2022;2022:5818423.
39. Liu JA, Yang IY, Tsai EB. Artificial Intelligence (AI) for Lung Nodules, From the AJR Special Series on AI Applications. *AJR Am J Roentgenol*. 2022 Nov;219(5):703-12.
40. Ather S, Kadir T, Gleeson F. Artificial intelligence and radiomics in pulmonary nodule management: current status and future applications. *Clin Radiol*. 2020 Jan;75(1):13-9.
41. Siegel RL, Miller KD, Jemal A. Cancer statistics, 2018. *CA Cancer J Clin*. 2018 Jan;68(1):7-30.
42. Ewals LJS, van der Wulp K, van den Borne BEEM, Pluyter JR, Jacobs I, Mavroeidis D, et al. The Effects of Artificial Intelligence Assistance on the Radiologists' Assessment of Lung Nodules on CT Scans: A Systematic Review. *J Clin Med*. 2023 May 18;12(10):3536.