

DA IMAGEM AO PROGNÓSTICO: O POTENCIAL DA RADIÔMICA E DA INTELIGÊNCIA ARTIFICIAL NA PREDIÇÃO DA RESPOSTA AO TRATAMENTO DO CÂNCER

FROM IMAGE TO PROGNOSIS: THE POTENTIAL OF RADIOMICS AND ARTIFICIAL INTELLIGENCE IN PREDICTING CANCER TREATMENT RESPONSE

Daniel Vinícius Cerqueira Coelho¹, Cláudia Virgínia de Carvalho Cerqueira², Davi Vinícius Cerqueira Coelho³, Katarinne Maria Rocha Moura Beer¹, Victor Menezes Cardoso², Taís Silva Souza¹.

1. Acadêmico do curso de Medicina do Centro Universitário de Maceió UNIMA-Afya.
 2. Professor do curso de Medicina do Centro Universitário de Maceió UNIMA-Afya.
 3. Médico Residente de Radiologia e Diagnóstico por Imagem – HUAP/ Universidade Federal Fluminense.
- daniellviniciuss23@gmail.com

EIXO: Tecnologia e inovação

RESUMO

Introdução: O planejamento terapêutico oncológico personalizado esbarra na limitação de biópsias tradicionais em capturar a heterogeneidade tumoral. **Objetivo:** Avaliar as evidências práticas sobre o potencial da radiômica e da inteligência artificial na predição do prognóstico e da resposta terapêutica em pacientes com câncer. **Método:** Revisão integrativa desenvolvida de 2020 a 2026 nas bases PubMed, Scopus, Web of Science, BVS e MedLine. De 420 artigos identificados, 5 atenderam rigorosamente aos critérios de inclusão e exclusão. **Resultados:** As características de textura e a heterogeneidade espacial apresentaram o maior potencial preditivo para antecipar a resposta terapêutica. Redes neurais profundas entregam alta acurácia, mas demandam forte controle analítico contra sobreajuste local. O uso hospitalar real ainda sofre com a escassez de validações externas e com falhas de reprodutibilidade entre marcas de tomógrafos. **Conclusão:** A tecnologia possibilita tratamentos customizados práticos, contudo sua consolidação na rotina oncológica depende da criação de diretrizes globais e de testes multicêntricos independentes.

Palavras-chave: Inteligência Artificial. Neoplasias. Radiômica. Prognóstico.

ABSTRACT

Introduction: Personalized oncological therapeutic planning faces limitations from traditional biopsies in capturing tumor heterogeneity. **Objective:** To evaluate practical evidence regarding the potential of radiomics and artificial intelligence in predicting prognosis and therapeutic response in cancer patients. **Method:** Integrative review developed from 2020 to 2026 across PubMed, Scopus, Web of Science, VHL, and MedLine databases. From 420 identified articles, 5 strictly met the inclusion and exclusion criteria. **Results:** Texture characteristics and spatial heterogeneity showed the highest predictive potential for anticipating therapeutic response. Deep neural networks deliver high accuracy but require strong analytical control against local overfitting. Actual hospital use still suffers from a scarcity of external validations and reproducibility flaws among scanner brands. **Conclusion:** The technology enables practical customized treatments; however, its consolidation into oncological routine depends on establishing global guidelines and independent multicenter trials.

Keywords: Artificial Intelligence. Neoplasms. Radiomics. Prognosis.

INTRODUÇÃO

O desenho de tratamentos oncológicos customizados enfrenta barreiras reais diante das limitações das biópsias convencionais, que não conseguem acompanhar as mudanças e a complexidade de um tumor em tempo real.¹ Nesse contexto, os exames de imagem de rotina ganharam um novo papel, deixando de ser meras fotos da anatomia para funcionar como bancos de dados biológicos ocultos.² A radiômica possibilita essa transição ao extrair métricas matemáticas que passam despercebidas no exame visual comum, como pequenos arranjos de textura, assimetria de formas e variações sutis de intensidade, convertendo a imagem diagnóstica em informação estruturada.³

Esse volume de dados ganha utilidade prática ao ser processado por modelos de inteligência artificial, englobando desde técnicas tradicionais de aprendizado de máquina até redes neurais profundas.⁴ Em vez de apenas automatizar a identificação de nódulos ou lesões, o cruzamento da inteligência artificial com a radiômica foca em prever o comportamento da doença e a resposta terapêutica. A intenção central é correlacionar essas assinaturas digitais a desfechos clínicos futuros, gerando bases para antecipar se o paciente terá boa resposta a tratamentos como quimioterapia, radioterapia ou imunoterapia antes mesmo da aplicação da primeira dose.⁵

Apesar do volume crescente de pesquisas científicas, a chegada dessa tecnologia à beira do leito ainda esbarra em obstáculos severos. Estudos recentes apontam falhas críticas de reprodutibilidade, impulsionadas pela sensibilidade dos modelos a variações técnicas entre

marcas de tomógrafos e pela falta de uniformidade nos programas que processam as imagens. Sem testes rigorosos de validação externa em múltiplos centros de saúde, as ferramentas operam sob alto risco de erro fora do ambiente onde foram criadas, o que alimenta a desconfiança de órgãos regulatórios e de equipes médicas.⁵

Investigar os fatores práticos que determinam a viabilidade clínica desses modelos, superando o discurso comum sobre o potencial futuro da tecnologia, é o que move esta pesquisa.¹ O trabalho foi delimitado pelo seguinte questionamento: quais são as evidências atuais de que a radiômica associada à inteligência artificial pode utilizar características quantitativas de imagens médicas para prever o prognóstico e a resposta terapêutica em pacientes com câncer? O objetivo é avaliar a solidez dessas ferramentas na literatura, mapeando os métodos mais eficazes e as barreiras que atrasam a sua aplicação real na rotina hospitalar.¹

MÉTODO

Esta revisão integrativa, de caráter qualitativo e exploratório, foi conduzida para responder à seguinte questão: como a radiômica associada à inteligência artificial utiliza dados quantitativos de imagens médicas para prever o prognóstico e a resposta terapêutica no câncer? A busca pelos dados ocorreu entre os anos de 2020 e 2026. Foram consultadas as bases indexadas PubMed, Scopus, Web of Science, BVS e MedLine. A estratégia combinou termos das plataformas MeSH e DeCS (*Radiomics, Texture Analysis, Artificial Intelligence, Machine Learning, Deep Learning, Cancer Prognosis e Treatment Response*) por meio dos operadores lógicos AND e OR.

A seleção priorizou artigos originais focados no potencial preditivo de feições radiômicas (forma, textura e intensidade) e no desempenho de algoritmos de IA na antecipação da resposta ao tratamento. Também foram incluídos estudos que discutiam a reprodutibilidade dos dados entre diferentes centros médicos, a validação externa dos modelos e os gargalos da translação clínica na oncologia. Foram excluídos os trabalhos limitados ao diagnóstico inicial, metodologias sem detalhamento da extração de características ou dos algoritmos, revisões de literatura, duplicatas e produções que não correlacionavam as imagens aos desfechos clínicos.

O levantamento inicial resultou em 420 artigos potencialmente elegíveis. Após a exclusão de duplicatas e a triagem inicial por títulos e resumos, restaram 150 publicações para

leitura na íntegra. A análise detalhada desses textos levou à exclusão de 145 trabalhos por inconsistências metodológicas, falta de validação externa ou ausência de discussão sobre a aplicabilidade prática nos hospitais. Desse modo, a base analítica desta revisão foi consolidada com 5 artigos que atenderam rigorosamente a todos os critérios estabelecidos.

RESULTADOS

A análise detalhada das pesquisas selecionadas permitiu agrupar as evidências científicas em três eixos temáticos fundamentais para o prognóstico oncológico: o mapeamento das feições de imagem com maior valor preditivo, o desempenho comparativo dos modelos computacionais e os entraves de reprodutibilidade para o uso clínico real. Esses eixos respondem diretamente aos questionamentos sobre como a extração de dados matemáticos ocultos em exames de rotina pode antecipar a resposta biológica dos tumores. Para fins de síntese e comparação visual dos principais achados de cada pesquisa mapeada, os dados estruturados foram consolidados na Tabela 1.

Tabela 1: Variáveis prognósticas e limitações práticas das pesquisas selecionadas

Estudo e Ano	Foco Tumoral	Feição de Maior Impacto	Modelo Computacional	Principal Gargalo Identificado
Bera et al., 2022 ¹	Pulmão e Mama	Heterogeneidade de textura	Aprendizado clássico e CNN	Variabilidade técnica entre tomógrafos
Zhang et al., 2023 ²	Múltiplos tumores	Métricas de intensidade	SVM e Random Forest	Falta de padrão nos softwares de extração
Sun et al., 2021 ³	Cabeça, Pescoço e Pulmão	Arranjos microestruturais	Redes neurais profundas	Alto risco de sobreajuste local
Chen et al., 2022 ⁴	Colorretal e Próstata	Assimetria de formas	Redes convolucionais	Queda de eficácia em centros externos
Avanzo et al., 2020 ⁵	Sarcomas e Pulmão	Matrizes de textura	Machine vs Deep Learning	Necessidade de calibração prévia rigorosa

Fonte: Elaborada pelos autores (2026).

Os dados da literatura demonstram que as características radiômicas de textura e a heterogeneidade espacial interna da massa tumoral são as variáveis com maior potencial preditivo. Esses arranjos conseguem capturar variações milimétricas na densidade celular e na vascularização do tecido, superando métricas tradicionais como o diâmetro macroscópico do nódulo.¹ O estudo do microambiente tumoral revela que essa assinatura digital confere a capacidade de antecipar o sucesso ou a falha de esquemas de quimioterapia, radioterapia e imunoterapia antes de qualquer alteração visível no tamanho do tumor.² Essa antecipação ocorre porque as mudanças microestruturais induzidas pelo tratamento precedem a retração física da lesão.

Relativamente ao desempenho dos modelos matemáticos, os resultados apontam uma clara distinção entre as abordagens de aprendizado de máquina clássico, como as máquinas de vetores de suporte (SVM) e florestas aleatórias, e as redes neurais profundas.⁴ Enquanto os algoritmos tradicionais dependem de uma engenharia de feições manual, as redes profundas e os modelos híbridos mostram maior autonomia para processar grandes volumes de dados de imagem, identificando padrões complexos de forma tridimensional. Contudo, esse poder de processamento exige um rigor estatístico estrito durante o treinamento. Os algoritmos de aprendizado profundo apresentam tendência ao sobreajuste, funcionando bem nos bancos de dados locais, mas perdendo eficiência quando confrontados com novas variáveis.⁵

Por fim, no eixo focado nos obstáculos para a translação clínica, as evidências convergem para a existência de gargalos severos de reprodutibilidade e padronização entre diferentes hospitais. Os modelos desenvolvidos nas pesquisas demonstram sensibilidade técnica extrema a variações de fabricantes de tomógrafos ou ressonâncias, além de sofrerem distorções causadas pela falta de uniformidade nos programas utilizados para a extração das feições radiômicas.² A análise indica que a maioria das ferramentas carece de testes de validação externa em coortes independentes e multicêntricas de pacientes. Sem essa validação fora do ambiente onde os algoritmos foram programados, as decisões operam sob risco de erro, o que justifica a atual desconfiança de órgãos regulatórios e de equipes médicas em adotar a tecnologia no prontuário diário.³

CONCLUSÃO

As evidências confirmam que a inteligência artificial aliada à radiômica consegue antecipar a resposta tumoral antes de mudanças físicas macroscópicas, tendo na

heterogeneidade de textura seu principal biomarcador. Esta revisão contribui para a ciência ao mapear que, embora as redes profundas tragam maior acurácia no processamento, elas exigem controle rígido contra o sobreajuste local.

Na prática, a tecnologia possibilita tratamentos customizados, mas sua aplicação real depende de superar a falta de padronização entre marcas de tomógrafos. Pesquisas futuras devem focar em diretrizes globais e testes de validação externa multicêntrica para garantir a reprodutibilidade e a segurança exigidas pelos médicos.

REFERÊNCIAS

1. Bera K, Braman N, Gupta A, Velcheti V, Madabhushi A. Predicting cancer outcomes with radiomics and artificial intelligence in radiology. *Nat Rev Clin Oncol*. 2022 Feb;19(2):132-146. doi: 10.1038/s41571-021-00560-7.
2. Zhang YP, Zhang XY, Cheng YT, Li B, Teng XZ, Zhang J, et al. Artificial intelligence-driven radiomics study in cancer: the role of feature engineering and modeling. *Mil Med Res*. 2023 May 16;10(1):22. doi: 10.1186/s40779-023-00458-8.
3. Sun R, Lerousseau M, Henry T, Carré A, Leroy A, Estienne T, et al. Intelligence artificielle en radiothérapie : radiomique, pathomique, et prédiction de la survie et de la réponse aux traitements [Artificial intelligence, radiomics and pathomics to predict response and survival of patients treated with radiations]. *Cancer Radiother*. 2021 Oct;25(6-7):630-637. French. doi: 10.1016/j.canrad.2021.06.027.
4. Chen MM, Terzic A, Becker AS, Johnson JM, Wu CC, Wintermark M, et al. Artificial intelligence in oncologic imaging. *Eur J Radiol Open*. 2022 Sep 29;9:100441. doi: 10.1016/j.ejro.2022.100441.
5. Avanzo M, Wei L, Stancanello J, Vallières M, Rao A, Morin O, et al. Machine and deep learning methods for radiomics. *Med Phys*. 2020 Jun;47(5):e185-e202. doi: 10.1002/mp.13678.