REVISÃO DE LITERATURA IDENTIFICADO

APLICAÇÃO DE MODELOS DE INTELIGÊNCIA ARTIFICIAL E VISÃO COMPUTACIONAL NA IDENTIFICAÇÃO DE PADRÕES MORFOLÓGICOS E NO APOIO DIAGNÓSTICO EM HISTOPATOLOGIA DIGITAL

APPLICATION OF ARTIFICIAL INTELLIGENCE AND COMPUTER VISION MODELS IN THE IDENTIFICATION OF MORPHOLOGICAL PATTERNS AND DIAGNOSTIC SUPPORT IN DIGITAL HISTOPATHOLOGY

Gabriel Henrique Carvalho Leite Romeiro[1]*, Vitor Comassetto Paes[1], Larissa Leite de Souza Leão[1], Luciano Timbó Barbosa[2], Jessyca Lane Fausto Lira[2], Reinaldo dos Santos Moura[2]

[1]Acadêmicos de Medicina, Afya Centro Universitário de Maceió (UNIMA); [2]Docente do Curso de Medicina, Afya Centro Universitário de Maceió (UNIMA).

*Autor principal. E-mail: gabriel.romeiro@alunos.afya.com.br

Eixo: 03 - Tecnologia e Inovação

RESUMO

Contexto: A digitalização de lâminas por Whole-Slide Imaging (WSI), associada a modelos de inteligência artificial (IA) e visão computacional, tem sido aplicada ao reconhecimento automatizado de padrões morfológicos e ao apoio diagnóstico em histopatologia. Objetivo: Analisar as aplicações contemporâneas de IA e visão computacional na identificação de padrões morfológicos e no apoio ao diagnóstico em histopatologia digital. Método: Revisão integrativa (Whittemore e Knafl, 2005), com busca reproduzível no PubMed/MEDLINE (6.259 registros, 2021-2026, via API E-utilities), complementada por Scopus, Web of Science, IEEE Xplore e Google Scholar e por trabalhos seminais; triagem por um único revisor; avaliação de qualidade dos estudos primários de acurácia diagnóstica pelo QUADAS-2. Resultados: Foram incluídos 24 artigos; 7 estudos primários foram avaliados pelo QUADAS-2, dos quais 6 receberam julgamento de risco de viés (predomínio moderado a alto) e 1 não pôde ser avaliado por falta de acesso ao texto completo. Conclusão: Modelos de IA e visão computacional apresentam desempenho consistente na identificação de padrões morfológicos; seu uso para diagnóstico clínico mais precoce e para padronização internacional do ensino permanece hipótese não demonstrada.

Palavras-chave: Inteligência Artificial; Aprendizado Profundo; Patologia Digital; Processamento de Imagem Assistido por Computador; Neoplasias.

ABSTRACT

Background: Whole-Slide Imaging (WSI) digitization, combined with artificial intelligence (AI) and computer vision models, has been applied to automated recognition of morphological patterns and diagnostic support in histopathology. Objective: To analyze contemporary applications of AI and computer vision in the identification of morphological patterns and diagnostic support in digital histopathology. Methods: Integrative review (Whittemore and Knafl, 2005), with a reproducible search in PubMed/MEDLINE (6,259 records, 2021-2026, via E-utilities API), complemented by Scopus, Web of Science, IEEE Xplore and Google Scholar, and by seminal works; screening by a

single reviewer; quality assessment of primary diagnostic accuracy studies using QUADAS-2. Results: Twenty-four articles were included; 7 primary studies were assessed with QUADAS-2, of which 6 received a risk-of-bias judgment (predominantly moderate to high) and 1 could not be assessed due to lack of full-text access. Conclusion: AI and computer vision models show consistent performance in identifying morphological patterns; their use for earlier clinical diagnosis and for international standardization of teaching remains an unproven hypothesis.

Keywords: Artificial Intelligence; Deep Learning; Digital Pathology; Computer-Assisted Image Processing; Neoplasms.

1. INTRODUÇÃO

A histopatologia é pilar da formação médica. Seu ensino tradicional depende de microscopia óptica sobre lâminas de vidro, o que limita a padronização de casos entre instituições[1]. A digitalização por Whole-Slide Imaging (WSI) converte a lâmina em imagem digital compartilhável[1,2], e a IA/visão computacional ampliou o reconhecimento automatizado de padrões morfológicos[3], criando infraestrutura para acesso comparável entre instituições[2,4], hipótese discutida na seção 3.4.

O eixo central desta revisão é outro: esses modelos têm sido aplicados diretamente ao apoio diagnóstico, com destaque para padrões tumorais em imagens de hematoxilina-eosina[5,6], ainda que a relação entre classificação retrospectiva e diagnóstico precoce exija distinção cuidadosa. Objetivo: analisar as aplicações contemporâneas de IA e visão computacional na identificação de padrões morfológicos e no apoio diagnóstico em histopatologia digital, e em que medida essa capacidade técnica permite inferir diagnóstico mais precoce.

2. MÉTODO

Revisão integrativa (Whittemore e Knafl, 2005). No PubMed/MEDLINE, busca estruturada combinando termos de IA/visão computacional com “digital pathology”, “whole slide imaging” e “computational pathology” retornou 6.259 registros (2021-2026); números intermediários de triagem não foram registrados de forma reprodutível, limitação declarada. Scopus, Web of Science e IEEE Xplore não tiveram acesso institucional para números reais. Triagem por um único revisor, sem segundo avaliador, limitação declarada.

Os sete estudos primários de acurácia diagnóstica foram avaliados pelo QUADAS-2 (Tabela 1); seis receberam julgamento completo e um não pôde ser avaliado por falta de texto acessível. Por não envolver dados primários de seres humanos ou animais, dispensa-se apreciação por Comitê de Ética.

3. RESULTADOS

3.1 Digitalização e transformação do ensino de Histopatologia

WSI permite que a mesma lâmina seja vista por múltiplos estudantes em localidades diferentes[1,2]. Elmore et al.[7] encontraram boa aceitação do WSI entre residentes, e Christian e VanSandt[8] descreveram seu uso durante a pandemia. QuPath Edu/OpenMicroanatomy[9] e a IA generativa de Roy et al.[10] sugerem viabilidade, mais do que ganho de aprendizagem comprovado.

3.2 Modelos AI-driven e visão computacional na interpretação histopatológica

Coudray et al.[5] mostraram redes convolucionais classificando câncer de pulmão com desempenho comparável a patologistas (AUC 0,97). Campanella et al.[6] alcançaram AUC > 0,98 para próstata, basocelular e metástases de mama com Multiple Instance Learning.

O campo incorporou foundation models autossupervisionados: CONCH[11], Virchow[12], TITAN[13], UNI[14] e Prov-GigaPath[15]. Benchmark clínico independente[16] mostrou variação relevante de desempenho por centro de origem.

3.3 Aplicações para identificação de alterações patológicas e apoio diagnóstico

A Tabela 1 sintetiza desenho, validação, métrica e risco de viés (QUADAS-2) de cada estudo.

Tabela 1. Síntese comparativa de desenho, validação, métrica e risco de viés (QUADAS-2).

Estudo	N	Validação	Métrica	QUADAS-2
Coudray et al.[5]	WSI TCGA	Retrospectiva, interna	AUC 0,97	Alto risco
Campanella et al.[6]	44.732 WSI/15.187 pac.	Retrospectiva, interna	AUC > 0,98	Risco moderado
Virchow[12]	1,5 milhão WSI/~100 mil pac.	Retrospectiva, parc. externa	AUC 0,95	Alto risco
Campanella et al.[16]	3 centros	Benchmark clínico, externo	Variação entre modelos/centros	Risco moderado
McGenity et al.[17]	100 estudos/>152 mil WSI	Metanálise (mista)	Sensib. 96,3% / Espec. 93,3%	99% alto risco*
Deepath-MSI[18]	5.070 WSI/7 coortes	Mundo real, externa	AUROC 0,98 / Sensib. 94,6%	Risco moderado
Wang et al.[19]	16.056 participantes	Prospectiva	AUC 0,947	Baixo/moderado
Huang et al.[20]	2 patologistas, crossover	Prospectiva (crossover)	Sensib. 74,5%→93,5%	Não avaliado

**Metanálise: reproduz avaliação de risco de viés já publicada pelos próprios autores.*

McGenity et al.[17] encontraram sensibilidade média de 96,3% e especificidade de 93,3%, mas 99% dos estudos com alto risco de viés. Deepath-MSI[18] alcançou AUROC 0,98 para microssatélites, e

Wang et al.[19] validaram prospectivamente, em 16.056 participantes, IA para citologia cervical (AUC 0,947).

A capacidade demonstrada refere-se majoritariamente à classificação retrospectiva, não a antecipação real do diagnóstico. Nenhum estudo demonstrou redução do tempo até o diagnóstico em coortes prospectivas; atribuir "diagnóstico precoce" a esses modelos caracteriza inferência dos autores, mesmo entre os estudos de menor risco de viés (Tabela 1).

Huang et al.[20] descreveram colaboração patologista-IA que aumentou a sensibilidade de 74,5% para 93,5% na identificação de metástases linfonodais, reduzindo o tempo de leitura em mais de 50%.

3.4 Perspectivas para padronização internacional do ensino

EMPAIA[4] e Piya e Lennerz[21] discutem o potencial da patologia digital em países de baixa renda. Obstáculos persistem: variabilidade entre scanners[22]; datasets pouco transparentes[23]; vieses de dados, desenvolvimento e interação[24]. A padronização global do ensino é potencial plausível, não realidade implementada.

4. CONCLUSÃO

Modelos de IA e visão computacional apresentam desempenho tecnicamente elevado na identificação de padrões morfológicos; foundation models recentes e uma metanálise confirmam essa tendência, com risco de viés relevante.

Esta revisão não encontrou evidência direta de diagnóstico precoce no sentido estrito, nem de padronização internacional já consolidada; a digitalização por WSI permanece direção futura condicionada a validação prospectiva, controle de vieses e evidência de desfecho educacional.

Conclui-se que a IA e a visão computacional não substituem o patologista, mas funcionam como apoio em modelo de colaboração humano-IA.

REFERÊNCIAS BIBLIOGRÁFICAS

1. Hamilton PW, Wang Y, McCullough SJ. Virtual microscopy and digital pathology in training and education. APMIS. 2012;120(4):305-315.

2. Williams BJ. Practical guide to the use of digital slides in histopathology education. J Clin Pathol. 2024. doi:10.1136/jcp-2024-209415.

3. Bera K, Schalper KA, Rimm DL, Velcheti V, Madabhushi A. Artificial intelligence in digital pathology: new tools for diagnosis and precision oncology. Nat Rev Clin Oncol. 2019;16(11):703-715.

4. Zerbe N, Schwen LO, Geißler C, Wiesemann K, Bisson T, Boor P, et al. Joining forces for pathology diagnostics with AI assistance: The EMPAIA initiative. J Pathol Inform. 2024;15:100387.
5. Coudray N, Ocampo PS, Sakellaropoulos T, Narula N, Snuderl M, Fenyö D, et al. Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning. Nat Med. 2018;24(10):1559-1567.
6. Campanella G, Hanna MG, Geneslaw L, Miraflor A, Werneck Krauss Silva V, Busam KJ, et al. Clinical-grade computational pathology using weakly supervised deep learning on whole slide images. Nat Med. 2019;25(8):1301-1309.
7. Elmore JG, Shucard H, Lee AC, Wang PC, Kerr KF, Carney PA, et al. Pathology Trainees' Experience and Attitudes on Use of Digital Whole Slide Images. Acad Pathol. 2020;7:2374289520951922.
8. Christian RJ, VanSandt M. Using Dynamic Virtual Microscopy to Train Pathology Residents During the Pandemic: Perspectives on Pathology Education in the Age of COVID-19. Acad Pathol. 2021;8:23742895211006819.
9. Yli-Hallila A, Bankhead P, Arends MJ, Lehenkari P, Palosaari S. QuPath Edu and OpenMicroanatomy: open-source virtual microscopy tools for medical education. J Anat. 2025;246(5):846-856.
10. Roy AD, Dasgupta S, Roy RD, Das D. The use of generative artificial intelligence (AI) in teaching and assessment of postgraduate students in pathology and microbiology. Indian J Microbiol Res. 2024;11(3):140-146.
11. Lu MY, Chen B, Williamson DFK, Chen RJ, Liang I, Ding T, et al. A visual-language foundation model for computational pathology. Nat Med. 2024;30(3):863-874.
12. Vorontsov E, Bozkurt A, Casson A, Shaikovski G, Zelechowski M, Severson K, et al. A foundation model for clinical-grade computational pathology and rare cancers detection. Nat Med. 2024;30(10):2924-2935.
13. Ding T, Wagner SJ, Song AH, Chen RJ, et al. A multimodal whole-slide foundation model for pathology. Nat Med. 2025;31(11):3749-3761.
14. Chen RJ, Ding T, Lu MY, Williamson DFK, Jaume G, Song AH, et al. Towards a general-purpose foundation model for computational pathology. Nat Med. 2024;30(3):850-862.

15. Xu H, Usuyama N, Bagga J, Zhang S, Rao R, Naumann T, et al. A whole-slide foundation model for digital pathology from real-world data. Nature. 2024;630:181-188.
16. Campanella G, Chen S, Singh M, Verma R, Muehlstedt S, Zeng J, et al. A clinical benchmark of public self-supervised pathology foundation models. Nat Commun. 2025;16:3640.
17. McGenity C, Clarke EL, Jennings C, Matthews G, Cartlidge C, Freduah-Agyemang H, et al. Artificial intelligence in digital pathology: a systematic review and meta-analysis of diagnostic test accuracy. NPJ Digit Med. 2024;7:114.
18. Feng X, Yin W, Ye Q, Chi Y, Wen H, Sun Y, et al. Deepath-MSI: a clinic-ready deep learning model for microsatellite instability detection in colorectal cancer using whole-slide imaging. NPJ Precis Oncol. 2025;9:302.
19. Wang J, Yu Y, Tan Y, Wan H, Zheng N, He Z, et al. Artificial intelligence enables precision diagnosis of cervical cytology grades and cervical cancer. Nat Commun. 2024;15:4369.
20. Huang Z, Yang E, Shen J, Gratzinger D, Eyerer F, Liang B, et al. A pathologist-AI collaboration framework for enhancing diagnostic accuracies and efficiencies. Nat Biomed Eng. 2025;9(4):455-470.
21. Piya S, Lennerz JK. Sustainable development goals applied to digital pathology and artificial intelligence applications in low- to middle-income countries. Front Med (Lausanne). 2023;10:1146075.
22. Xu C, Sun Y, Zhang Y, Liu T, Wang X, Hu D, et al. Stain Normalization of Histopathological Images Based on Deep Learning: A Review. Diagnostics (Basel). 2025;15(8):1032.
23. Alderman JE, Palmer J, Laws E, et al. Tackling algorithmic bias and promoting transparency in health datasets: the STANDING Together consensus recommendations. Lancet Digit Health. 2025;7(1):e64-e88.
24. Hanna MG, Pantanowitz L, Jackson B, Palmer O, Visweswaran S, Pantanowitz J, et al. Ethical and Bias Considerations in Artificial Intelligence/Machine Learning. Mod Pathol. 2025;38(3):100686.