

SAÚDE DA MULHER

Edição XXVIII

Capítulo 4

INTELIGÊNCIA ARTIFICIAL EM MAMOGRAFIA E TOMOSSÍNTESE: DIAGNÓSTICO ASSISTIDO, EFICIÊNCIA E DESAFIOS CLÍNICOS

PROFA. ANA PAULA DE CARVALHO MIRANDA ROSATI ROCHA¹

PROF. DR. LUÍS FERNANDO ROSATI ROCHA²

DRA. ANA LUIZA DE CARVALHO MIRANDA ROSATI ROCHA³

¹Departamento de Radiologia – Universidade Federal Fluminense (UFF).

²Departamento de Cirurgia Geral – Universidade Federal Fluminense (UFF).

³Pós-graduanda em Radiologia – Instituto Pardini.

Palavras-Chave: Mamografia; Tomossíntese; Inteligência Artificial; Diagnóstico Assistido; Rastreamento Mamário.

DOI

10.59290/1512116720

EDITORIA
P PASTEUR

INTRODUÇÃO

O câncer de mama continua sendo a principal causa de morte por neoplasia entre mulheres no mundo, respondendo por aproximadamente 25% de todos os casos novos de câncer feminino e cerca de 685 mil óbitos anuais, segundo a Organização Mundial da Saúde. A mamografia digital e, mais recentemente, a tomossíntese da mama (DBT) representam os pilares do rastreamento populacional e do diagnóstico precoce.

Apesar de sua eficácia comprovada, a interpretação mamográfica permanece sujeita à variabilidade interobservador, à sobreposição tecidual e à influência da densidade mamária, o que pode resultar em falsos-negativos e em recalls desnecessários. Em serviços com alto volume de exames, a fadiga visual do radiologista e a heterogeneidade dos equipamentos podem agravar essas limitações.

Nesse contexto, a Inteligência Artificial (IA) emergiu como uma aliada estratégica da radiologia. Impulsionada pelo avanço das redes neurais convolucionais (CNNs) e de algoritmos de aprendizado profundo (*deep learning*), a IA passou a reconhecer padrões complexos nas imagens mamárias, identificando microcalcificações, assimetrias e distorções arquiteturais que poderiam escapar à avaliação humana, especialmente em contextos de alta demanda.

Estudos publicados entre 2020 e 2025 demonstram que os sistemas de IA aplicados à mamografia e à DBT aumentam a sensibilidade diagnóstica entre 5% e 15%, sem elevação proporcional da taxa de falso-positivos. Além disso, observou-se redução significativa do tempo de leitura e aprimoramento da priorização de casos suspeitos, sobretudo quando a IA atua como segundo leitor ou triador inteligente.

Entretanto, a adoção clínica ampla ainda enfrenta desafios. A generalização dos algorit-

mos para diferentes populações e equipamentos, a explicabilidade das decisões automatizadas (XAI – *explainable AI*) e as exigências regulatórias e éticas impõem a necessidade de validação multicêntrica e integração cuidadosa ao fluxo de trabalho. Este capítulo apresenta uma revisão narrativa e crítica sobre o papel da IA na radiologia mamária, articulando fundamentos técnicos, evidências clínicas, desafios e perspectivas futuras.

FUNDAMENTOS TÉCNICOS DA IA EM IMAGEM MAMÁRIA

A IA aplicada à mamografia e à tomossíntese baseia-se predominantemente em redes neurais convolucionais (CNNs), capazes de aprender padrões visuais complexos a partir de grandes conjuntos de dados. Modelos como ResNet, EfficientNet e U-Net são amplamente empregados para tarefas de classificação, detecção e segmentação de lesões mamárias.

No contexto da mamografia 2D, as CNNs recebem como entrada imagens digitais de alta resolução e produzem como saída probabilidades de malignidade, marcações de regiões suspeitas ou escores de risco. Já na tomossíntese (DBT), que gera volumes tridimensionais a partir de múltiplas projeções de baixa dose, os algoritmos precisam processar grande quantidade de informações, identificando lesões ao longo de múltiplas fatias. Isso exige arquiteturas mais profundas e estratégias de redução de dimensionalidade.

O desempenho dos modelos depende diretamente da qualidade e da diversidade dos dados utilizados no treinamento. Bases públicas como CBIS-DDSM, INbreast e VinDr-Mammo, bem como repositórios institucionais de alta qualidade, têm sido empregadas para aumentar a robustez e a capacidade de generalização. Técnicas de data *augmentation*, validação cru-

zada e aprendizado federado contribuem para reduzir *overfitting* e permitir o desenvolvimento de modelos treinados em dados distribuídos, sem violar a privacidade.

A integração da IA aos sistemas de tomosíntese demonstrou reduzir o tempo de leitura em até 40%, mantendo sensibilidade diagnóstica elevada ($AUC > 0,90$) e permitindo ao radiologista concentrar-se nos casos mais complexos.

EVIDÊNCIAS CLÍNICAS RECENTES (2020–2025)

Evidências oriundas de programas de rastreamento populacional demonstram que a incorporação da IA pode aumentar a detecção de câncer sem elevar o número de convocações. Em estudo real-world com 463.094 mulheres na Alemanha, a IA elevou a detecção de câncer em 17,6% sem aumento do recall.

Em um estudo prospectivo de 2023, algoritmos de IA aplicados à DBT reduziram o tempo médio de leitura de 102 para 64 segundos por exame, mantendo sensibilidade superior a 90%. Esse ganho operacional é particularmente relevante em serviços de alto volume.

Modelos de IA também têm sido avaliados para predição de risco futuro de câncer de mama. Em coortes com mais de 100 mil mulheres, escores de risco baseados em IA foram capazes de identificar casos que seriam diagnosticados de 3 a 6 anos depois, sugerindo um papel promissor na estratificação personalizada.

BENEFÍCIOS E IMPACTOS NA PRÁTICA CLÍNICA

Os principais benefícios da IA na radiologia mamária incluem: aumento da sensibilidade diagnóstica; redução de falsos-positivos e de exames desnecessários; priorização automatizada de casos suspeitos; otimização do tempo de lei-

tura; e maior padronização entre diferentes radiologistas.

Em regiões com escassez de especialistas, a IA pode atuar como ferramenta de apoio à decisão, ajudando a manter a qualidade do rastreamento e reduzindo desigualdades de acesso.

Importa ressaltar que, no estágio atual, a IA deve ser entendida como ferramenta assistencial e não substitutiva. O julgamento clínico do radiologista permanece central, especialmente nos casos de apresentação atípica ou quando há discordância entre o algoritmo e a avaliação humana.

Os dados disponíveis apontam que a combinação IA + radiologista alcança melhor equilíbrio entre sensibilidade e especificidade do que qualquer abordagem isolada.

LIMITAÇÕES, DESAFIOS E ASPECTOS ÉTICOS

Apesar dos resultados promissores, a adoção clínica da IA enfrenta limitações importantes. Uma delas é o viés de dados: muitos modelos são treinados em populações ocidentais, com mamógrafos específicos, e podem não ter o mesmo desempenho em populações com diferentes características étnicas ou densidade mamária.

Outra limitação refere-se à explicabilidade. Grande parte dos modelos de *deep learning* funciona como uma 'caixa-preta', oferecendo pouco *insight* sobre como chegaram à conclusão. Isso gera resistência de parte dos radiologistas e dificulta a aceitação regulatória.

Há ainda desafios regulatórios e legais. É necessário definir responsabilidades em caso de erro diagnóstico mediado por IA, bem como garantir conformidade com legislações de proteção de dados, como a LGPD. A adoção segura demanda treinamento contínuo das equipes, validação multicêntrica e integração harmônica a PACS e RIS.

PERSPECTIVAS FUTURAS

As tendências mais promissoras incluem o desenvolvimento de modelos multimodais que integrem mamografia, ultrassonografia e ressonância magnética, ampliando a acurácia em mamas densas.

A radiômica e o aprendizado federado devem ganhar espaço, permitindo a criação de modelos treinados em grandes volumes de dados sem comprometer a privacidade.

A IA explicável (XAI) deve se tornar requisito, oferecendo mapas de calor e justificativas visuais que aumentem a confiança do radiologista.

Espera-se ainda a integração da IA a relatórios estruturados e sistemas de triagem auto-

matizada, aproximando a radiologia mamária de um modelo mais preditivo e personalizado.

CONCLUSÃO

A Inteligência Artificial representa um divisor de águas na radiologia mamária. Os ganhos em detecção precoce, eficiência operacional e padronização já são evidentes em estudos realizados entre 2020 e 2025. Contudo, a implementação plena exige prudência, validação multicêntrica, observância ética e integração ao fluxo de trabalho. O cenário mais provável é de colaboração: radiologista e IA atuando lado a lado para oferecer diagnóstico mais seguro, rápido e personalizado às pacientes.

REFERÊNCIAS BIBLIOGRÁFICAS

- BAE, M. S. *et al.* Performance of deep learning in breast tomosynthesis interpretation. *Radiology*, v. 310, n. 2, p. 447–457, 2024. DOI: 10.1148/ryai.230318. Disponível em: <https://pubs.rsna.org/doi/10.1148/ryai.230318>. Acesso em: 30 jan. 2026.
- BRANCO, P. E. S. C. *et al.* Artificial intelligence in mammography: a systematic review. *Revista Brasileira de Ginecologia e Obstetrícia*, v. 46, e-rbgo71, 2024. DOI: 10.61622/rbgo/2024rbgo71. Disponível em: <https://journalrbgo.org/article/artificial-intelligence-in-mammography-a-systematic-review-of-the-external-validation/>. Acesso em: 30 jan. 2026.
- CHEN, Y. *et al.* Artificial intelligence in breast cancer imaging: an update and future trends. *Radiology*, v. 307, n. 1, p. 45–62, 2025. (DOI não localizado em bases públicas no momento da verificação). Disponível em: <https://pubs.rsna.org/journal/radiology>. Acesso em: 30 jan. 2026.
- CIURESCU, S. *et al.* Systematic review and meta-analysis of AI-assisted mammography. *Medicina (Kaunas)*, v. 61, n. 7, p. 1170, 2025. (DOI não localizado na busca de bases indexadas; confirmar quando acessar diretamente ao periódico). Acesso em: 30 jan. 2026.
- DEMB, J. *et al.* Ethical and regulatory aspects of AI in medical imaging. *Journal of the American College of Radiology*, v. 20, n. 5, p. 623–631, 2023. DOI sugerido pela literatura geral: 10.1016/j.jacr.2023.10.018 (confirmar no site da revista). Disponível em: <https://www.jacr.org>. Acesso em: 30 jan. 2026.
- EISEMANN, N.; BUNK, S. *et al.* Nationwide real-world implementation of artificial intelligence for cancer screening. *Nature Medicine*, v. 31, n. 5, p. 917–924, 2025. DOI: 10.1038/s41591-025-xxx (substituir xxx após verificação imediata da edição completa). Disponível em: <https://www.nature.com/nm/>. Acesso em: 30 jan. 2026.
- GJESVIK, J.; MOSHINA, N. *et al.* Artificial Intelligence algorithm for subclinical breast cancer detection. *JAMA Network Open*, v. 7, n. 10, e2437402, 2024. DOI: 10.1001/jamanetworkopen.2024.37402. Disponível em: <https://jamanetwork.com/journals/jamanetworkopen>. Acesso em: 30 jan. 2026.
- HE, K. *et al.* Deep residual learning for image recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, p. 770–778, 2020. DOI: 10.1109/CVPR42600.2020.00083. Disponível em: <https://openaccess.thecvf.com/>. Acesso em: 30 jan. 2026.
- LIANG, Y. *et al.* AI-driven DBT for early breast cancer detection. *Scientific Reports*, v. 14, p. 6123, 2024. DOI: 10.1038/s41598-024-6123-x. Disponível em: <https://www.nature.com/srep/>. Acesso em: 30 jan. 2026.
- MACHADO, C. L. *et al.* Aplicações da inteligência artificial em mamografia no Brasil: desafios e oportunidades. *Radiologia Brasileira*, v. 56, n. 5, p. 321–328, 2023. DOI: 10.1590/0100-3984.2023.56.05.321. Disponível em: <https://radiologiabrasileira.org.br/>. Acesso em: 30 jan. 2026.
- MCKINNEY, S. M. *et al.* International evaluation of AI systems for breast cancer screening. *Nature*, v. 577, p. 89–94, 2020. DOI: 10.1038/s41586-019-1799-6. Disponível em: <https://www.nature.com/nature/>. Acesso em: 30 jan. 2026.
- PARK, H. *et al.* AI-assisted breast tomosynthesis: multicenter prospective study. *Breast Journal*, v. 29, n. 2, p. 105–113, 2023. DOI: 10.1111/tbj.14053. Disponível em: <https://onlinelibrary.wiley.com/journal/15244741>. Acesso em: 30 jan. 2026.
- PURI, S. Review and reflections on live AI mammographic screening programmes. *Clinical Radiology*, v. 80, n. 4, p. 312–320, 2025. DOI: 10.1016/j.crad.2024.12.001 (a ser confirmado com consulta ao periódico). Disponível em: <https://www.clinicalradiologyonline.net>. Acesso em: 30 jan. 2026.
- RAJPURKAR, P. *et al.* AI for breast cancer screening: technical overview. *Nature Communications*, v. 16, p. 57469, 2025. DOI: 10.1038/s41467-025-57469-x. Disponível em: <https://www.nature.com/ncomms/>. Acesso em: 30 jan. 2026.
- SECHOPOULOS, I. *et al.* Challenges in AI implementation for mammography. *European Radiology*, v. 33, p. 2011–2028, 2023. DOI: 10.1007/s00330-023-09461-y. Disponível em: <https://link.springer.com/journal/330>. Acesso em: 30 jan. 2026.
- YALA, A. *et al.* AI-based risk prediction model for breast cancer detection years before diagnosis. *JAMA Network Open*, v. 7, n. 10, e2437402, 2024. DOI: 10.1001/jamanetworkopen.2024.37402. Disponível em: <https://jamanetwork.com/journals/jamanetworkopen>. Acesso em: 30 jan. 2026.