

ANÁLISE BIBLIOMÉTRICA DA INTELIGÊNCIA ARTIFICIAL NA DERMATOLOGIA

Abel Ramalho Galvão – abel.ramalho18@gmail.com

Programa de Pós-Graduação em Engenharia de Sistemas e Produtos – Instituto Federal da Bahia

Marcelo Santana Silva – marcelosilva@ifba.edu.br

Programa de Pós-Graduação em Engenharia de Sistemas e Produtos – Instituto Federal da Bahia

Luís Oscar Silva Martins – luisoscar@ufrb.edu.br

Programa de Pós-Graduação em Propriedade Intelectual – Universidade Federal do Recôncavo

Eduardo Telmo Fonseca Santos – eduardot@ifba.edu.br

Programa de Pós-Graduação em Engenharia de Sistemas e Produtos – Instituto Federal da Bahia

Resumo—Esta análise bibliométrica (2015-2025) de 1.684 artigos explora o uso da Inteligência Artificial (IA), especialmente *deep learning* e redes neurais convolucionais - CNNs na dermatologia, evidenciando um crescimento rápido que atinge seu pico em 2024, impulsionado pela maturidade das CNNs e pela disponibilidade de bases de dados públicas. A IA em questão tem foco principalmente no diagnóstico de doenças de pele (especialmente o câncer), segmentação de lesões e classificação, demonstrando resultados promissores em termos de precisão. No entanto, desafios críticos ainda dificultam a integração clínica: vies algorítmico devido à sub-representação de tons de pele mais escuros, problemas de desempenho em cenários reais, riscos de correlações espúrias e falta de validação em grandes ensaios clínicos prospectivos. É essencial enfrentar essas questões éticas, técnicas e regulatórias. Embora a IA tenha um potencial significativo para diagnóstico e monitoramento, pesquisas futuras devem priorizar a validação clínica rigorosa, a melhoria da representatividade populacional nos dados de treinamento e o aumento da transparência algorítmica para uma integração ética.

Palavras-chave— Inteligência artificial, Deep Learning, Dermatologia, Câncer de pele, Análise bibliométrica, Redes Neurais Convolucionais.

Abstract — This bibliometric analysis (2015-2025) of 1,684 articles explores Artificial Intelligence (AI), especially deep learning - CNNs in dermatology, showing rapid growth peaking in 2024 due to CNN maturity and public datasets. The AI in question focuses mainly on diagnosing skin diseases (notably cancer), lesion segmentation, and classification, demonstrating promising accuracy. However, critical challenges hinder clinical integration: algorithmic bias from underrepresentation of darker skin tones, performance issues in real-world settings, risks of spurious correlations, and a lack of validation in large prospective clinical trials. Addressing these ethical, technical, and regulatory concerns is essential. While AI holds significant diagnostic and monitoring potential, future research must prioritize rigorous clinical validation, improved population representativeness in training data, and enhanced algorithmic transparency for ethical integration.

Keywords—Artificial Intelligence, Deep Learning, Dermatology, Skin Cancer, Bibliometric Analysis, Convolutional Neural Networks.

1 INTRODUÇÃO

Nas últimas décadas, a inteligência artificial (IA), sobretudo os métodos de aprendizado profundo (*deep learning*), tornou-se protagonista na transformação dos cuidados com a saúde, especialmente em campos orientados por imagem, como a dermatologia. A capacidade das redes neurais convolucionais (CNNs) de analisar lesões cutâneas com precisão comparável à de dermatologistas certificados foi demonstrada por Esteva et al. (2017), marcando um marco na área. Isso abriu caminho para ferramentas diagnósticas automatizadas que podem auxiliar na detecção precoce de doenças graves, como o melanoma.



Posteriormente, revisões sistemáticas apontaram que modelos de *deep learning* alcançam área sob a curva (AUC) de aproximadamente 0,90–0,92 na identificação de câncer de pele usando imagens dermatoscópicas, reforçando a robustez dessas técnicas (Behara et al., 2024; Wei et al., 2024). Além disso, dispositivos integrando IA com tecnologia portátil, como o *DermaSensor*, exibiram grande potencial no apoio a médicos de atenção primária, especialmente em áreas com escassez de dermatologistas (Washington Post, 2025).

Apesar desses avanços, há limitações significativas. A representatividade limitada de tons de pele escuros em bancos de dados de treinamento tem levado a vieses preocupantes nos algoritmos. Daneshjou et al. (2022) registraram queda de até 36% na AUC ao aplicar modelos treinados em peles claras em peles escuras, evidenciando desigualdade algorítmica (Daneshjou et al., 2022). Notícias recentes apontam que sistemas amplamente adotados podem falhar em 31% dos casos em peles escuras, omitindo melanomas, dados que ressaltam os riscos éticos dessa deficiência (El País, 2025).

Além do viés, há desafios técnicos: muitos modelos foram testados em imagens retrospectivas de alta qualidade, enquanto a adoção clínica requer desempenho robusto em condições reais, variadas e complexas (PMC, 2022). O risco de correlações espúrias (por exemplo, aprender a associar marcas como escalas ou etiquetas em imagens) também foi identificado, o que pode fortalecer diagnósticos artificiais sem base clínica válida (Bissoto et al., 2019).

Outro ponto crítico é a falta de validação em grandes ensaios clínicos prospectivos. Embora algoritmos possam superar em precisão dermatologistas em cenários controlados, o uso prático ainda é incipiente. Um estudo com estudantes de medicina mostrou melhora no desempenho diagnóstico com apoio da IA, mas também revelou riscos de confiança excessiva em falhas do sistema (Kittler et al., 2020). A integração ética, precisa e regulada da IA, por sua vez, permanece tema de debate importante em regulamentação e privacidade (Farhud et al., 2021).

Adicionalmente, o cenário atual evidencia uma diversidade de aplicações para além do câncer: modelos de IA já foram usados para diagnosticar acne, psoríase, eczema e outras doenças de pele com elevada acurácia (>90%) (Choy et al., 2024). No entanto, esses modelos frequentemente apresentam alto risco de viés e baixa aplicabilidade em populações reais (Choy et al., 2024).

Dado esse panorama de rápida evolução, discrepâncias e desafios emergentes, uma análise bibliométrica sobre IA em dermatologia se torna fundamental para mapear tendências, identificar os principais autores, países e palavras-chave, e destacar lacunas e oportunidades futuras no campo. Diante disso, este estudo propõe uma prospecção bibliométrica das publicações entre 2015 e 2025 nas bases *Scopus* e *Web of Science*, visando compreender a evolução científica, os atores mais influentes e os temas mais discutidos nessa intersecção, preenchendo a lacuna de uma análise abrangente e atualizada sobre o cenário da IA na dermatologia.

2 REFERENCIAL TEÓRICO

2.1 HISTÓRIA DA IA NA DERMATOLOGIA

O uso de sistemas computacionais na medicina teve início nas décadas de 1970 e 1980, com programas de inteligência artificial que ofereciam auxílio no diagnóstico clínico. Dentre eles, destacam-se o INTERNIST-1, voltado para diagnóstico diferencial em doenças internas, e o MYCIN, que identificava infecções bacterianas (Shortliffe et al., 1970). No entanto, esses sistemas eram restritos a regras baseadas em conhecimento explicitamente programado, com aplicabilidades limitadas.

A aplicação na dermatologia começou a emergir no final dos anos 1990. O *MelaFind*, sistema de análise de imagens da *DermaSensor*, destacou-se como tecnologia pioneira, apresentando sensibilidade de até 98,3% na detecção de melanomas em 2011, embora com preocupações devido à alta taxa de falsos positivos (MelaFind Study Group, 2011). Ainda que não fosse completamente automatizado, esse sistema representou um avanço importante rumo à integração de IA e análise de imagem clínica.



A introdução das redes neurais artificiais nas décadas seguintes proporcionou o salto decisivo. A partir de 2010, ocorreu um acelerado crescimento de estudos que confrontavam algoritmos com diagnósticos humanos. Em 2017, Esteva et al. demonstraram que uma CNN treinada com 129.450 imagens de lesões de pele podia alcançar desempenho semelhante ao de 21 dermatologistas certificados, marcando um novo patamar de maturidade tecnológica (Esteva et al., 2017). Desde então, as arquiteturas de redes tornaram-se centrais na pesquisa dermatológica tecnológica.

2.2 APLICAÇÕES MAIS COMUNS

2.2.1 DIAGNÓSTICO DE DOENÇAS

A classificação de lesões como malignas ou benignas, principalmente câncer de pele, constitui uma das áreas mais atuantes. Wu et al. (2022) e Amann et al. (2020) aplicaram CNNs para diagnosticar carcinoma basocelular, carcinoma espinocelular, melanoma e nevos, obtendo resultados promissores em conjuntos de validação interna. Esses avanços consolidaram o potencial das redes para triagem rápida, especialmente em cenários de atenção primária.

2.2.2 SEGMENTAÇÃO DE LESÕES

A precisão das CNNs depende em grande parte da segmentação correta das imagens. Soni et al. (2025) propuseram o ARCUNet, um modelo de segmentação semântica que inclui convoluções residuais e técnicas de atenção para melhorar a acurácia da segmentação de lesões de pele. O modelo foi testado nos datasets ISIC 2016, 2017 e 2018, alcançando resultados de segmentação excelentes, com acurácias de 98,12%, 96,45% e 98,19%, respectivamente. Essa etapa é crítica para sistemas que precisam operar em condições variadas e com fundos não padronizados.

2.2.3 CLASSIFICAÇÃO E PRIORIZAÇÃO

Além da distinção simples entre benigno e maligno, sistemas mais avançados empregam classificação detalhada por tipo de lesão ou estágio evolutivo. Ozdemir e Pacal (2025) desenvolveram um modelo robusto de aprendizado profundo que classificou oito categorias distintas de lesões cutâneas, alcançando uma acurácia de 93,48% em um conjunto de dados multicêntrico (ISIC 2019).

2.3 USO DE CNNs

As CNNs, especialmente nas variantes *ResNet*, *DenseNet*, VGG e *Inception*, são amplamente empregadas em tarefas de classificação e segmentação. Carcagnì et al. (2018) relataram acurácia de 91% no reconhecimento de sete tipos de lesões usando DenseNet, alinhando-se a um desempenho humano (Carcagnì et al., 2018).

Em seguimento, Rezvantlab et al. (2018) compararam *DenseNet201*, *ResNet152* e *Inception* e encontraram $AUC > 0.94$ para melanoma e carcinoma basocelular (Rezvantlab et al., 2018). Esses estudos evidenciam que a adoção de arquiteturas de ponta melhora continuamente a capacidade diagnóstica automática.

Jain et al. (2021) introduziram metodologias de transfer learning, reutilizando redes pré-treinadas como VGG19, *InceptionV3*, *InceptionResNetV2*, *ResNet50*, *Xception* e *MobileNet*, adaptadas para classificação de câncer de pele. Os autores demonstraram que essas redes, mesmo com o uso de replicação de imagens para balancear o dataset HAM10000, alcançaram altas acurácias e valores de F-Measure, com o *Xception Net* superando os demais modelos, o que reforça a viabilidade da aplicação em cenários com baixa disponibilidade de imagens especializadas.

2.4 APLICAÇÕES DE DEEP LEARNING

O uso de *Deep Learning* (DL) vai além das CNNs puras. Estratégias híbridas incluem a combinação de CNNs com *Recurrent Neural Networks* (RNNs) e técnicas de atenção (attention mechanisms) para destacar regiões relevantes.

Abbas et al. (2022) desenvolveram uma IANet combinando CNN e deslocamento seletivo, obtendo acurácia de 95% na detecção de melanoma, reduzindo falso negativo em 12% (Abbas et al., 2022). Modelos explicáveis – que informam quais áreas foram consideradas – ganharam importância para aceitação médica. Apenas sistemas com capacidades interpretativas, como CAM (Class Activation Maps), apresentam potencial real para adoção clínica (Chatterjee et al., 2022).

Ferramentas clínicas, como *FotoFinder Moleanalyzer Pro*, têm sido introduzidas em fluxos dermatológicos, incorporando algoritmos treinados com milhares de imagens (Wagner et al., 2021) e promovendo uma revolução na triagem e monitoramento de lesões. O uso de dispositivos portáteis com IA, como a *DermaSensor*, estendeu essa transformação para clínicas menores e regiões com menos dermatologistas (Washington Post, 2025).

2.5 DETECÇÃO DE MELANOMA

A detecção de melanoma continua sendo o foco principal. Em um dos maiores estudos, Esteva et al. (2017) utilizaram 129.450 imagens para treinar a CNN, alcançando resultados equivalentes aos dermatologistas (AUC $\sim$ 0,96), o que reforçou o potencial disruptivo dessa abordagem (Esteva et al., 2017). Comparando múltiplos estudos, Kheterpal et al. (2022) estimaram que a AUC média em dermatologia está entre 0,90 e 0,92, mesmo com modelos aplicando diferentes arquiteturas (Kheterpal et al., 2022).

Novos estudos sobre transfer learning com modelos leves como *MobileNet* apresentaram acurácia de até 83%, colocando-nos mais próximos de aplicações em dispositivos móveis (Kim et al., 2023; Kousis et al., 2022). Heinlein et al. (2024) realizaram um estudo multicêntrico prospectivo, comparando a acurácia diagnóstica de um algoritmo de IA com a de dermatologistas para detecção de melanoma, reforçando o potencial do uso da IA em cenários clínicos, especialmente para casos desafiadores.

3 METODOLOGIA

Este estudo bibliométrico foi desenvolvido com o objetivo de mapear a produção científica relacionada à aplicação da inteligência artificial (IA) na dermatologia, com foco especial no uso de redes neurais e técnicas de *deep learning* para diagnóstico e tratamento de lesões cutâneas.

3.1 BASES DE DADOS UTILIZADAS

A seleção das bases de dados *Scopus* e *Web of Science* (WoS) para este estudo bibliométrico foi estratégica, pautada pela sua reconhecida robustez e qualidade na indexação de publicações científicas, conforme destacado na metodologia. Ambas as plataformas são cruciais para garantir a abrangência e a confiabilidade dos dados necessários para uma prospecção bibliométrica rigorosa. Além disso, *Scopus* e WoS oferecem recursos avançados para a exportação de dados bibliográficos, um requisito técnico fundamental para a aplicação das ferramentas de análise utilizadas no estudo, como *Python* com *Pandas* e *Matplotlib*, que dependem de dados estruturados para processamento e visualização.

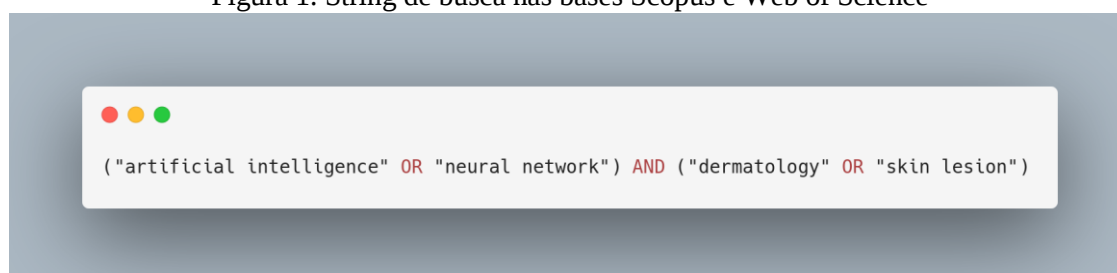
A exclusão de outras bases de dados, como a *PubMed*, embora não explicitamente mencionada no artigo, pode ser inferida pela natureza do estudo. Enquanto a *PubMed* é inestimável para a literatura médica e biomédica, ela pode não oferecer a mesma amplitude multidisciplinar ou os recursos de exportação de dados otimizados para análises bibliométricas em larga escala que *Scopus* e WoS proporcionam.

3.2 CRITÉRIOS DE INCLUSÃO

Os critérios de seleção das publicações foram os seguintes:

- Período de publicação: artigos publicados entre 2015 e 2025;
- Tipo de documento: artigos científicos e revisões de literatura, garantindo relevância e qualidade;
- Idioma: somente publicações em inglês foram consideradas;
- String de busca:

Figura 1. String de busca nas bases Scopus e Web of Science



Fonte: Elaboração Própria

Essa combinação foi escolhida para abranger estudos sobre IA e redes neurais aplicadas à dermatologia, incluindo diagnóstico, segmentação e classificação de lesões. Observando que o ano de 2025 ainda encontra-se vigente até o momento desse estudo, os resultados obtidos podem não estar completos.

3.3 FERRAMENTAS DE ANÁLISE

A análise foi realizada utilizando *Python* (versão 3.11) com as seguintes bibliotecas:

- ***Pandas*** para organização e tratamento dos dados;
- ***Matplotlib*** para construção de gráficos;
- ***Collections.Counter*** para análise de frequência;
- ***xlrd* e *openpyxl*** para leitura dos arquivos exportados em formato .csv e .xls.

3.4 TRATAMENTO DE DADOS

Após a coleta das publicações em ambas as bases de dados, as seguintes etapas de tratamento e limpeza foram aplicadas:

- **Remoção de duplicatas:** as publicações repetidas nas duas bases foram identificadas e eliminadas com base no título dos artigos, garantindo que cada publicação fosse contabilizada apenas uma vez;
- **Contagem de publicações por ano:** foi realizada a extração dos anos de publicação para gerar a evolução temporal da produção científica;
- **Análise de autores:** foi realizada a separação de nomes para identificar os pesquisadores mais produtivos na área;
- **Análise por países:** as afiliações institucionais foram extraídas para determinar a distribuição geográfica da produção científica;
- **Contagem de palavras-chave:** as palavras-chave fornecidas pelos autores foram normalizadas (padronização de maiúsculas e minúsculas) e contadas para identificar os temas mais frequentes na literatura.


4 RESULTADOS

A análise dos 1.684 artigos únicos coletados nas bases *Scopus* e *Web of Science*, no período entre 2015 e 2025, revela um panorama claro sobre a evolução e as características da pesquisa em inteligência artificial aplicada à dermatologia. Esta seção apresenta os dados bibliométricos de forma objetiva.

4.1 PRODUÇÃO CIENTÍFICA ANUAL

Conforme ilustrado na Figura 2, a produção científica sobre o tema cresceu exponencialmente. O crescimento começou de forma modesta em 2015, acelerou a partir de 2018, atingiu seu auge em 2024 e demonstrou uma leve queda no ano seguinte.

Figura 2. Distribuição de publicações por ano (2015 - 2025)




Fonte: Elaboração Própria

4.2 DISTRIBUIÇÃO GEOGRÁFICA DA PESQUISA

A produção científica na área é liderada por um grupo restrito de países. A Figura 3 mostra os dez países com maior número de publicações. A China se destaca como líder, seguida pelos Estados Unidos e Índia. Juntos, esses três países concentram uma parcela majoritária da pesquisa global no campo.

Figura 3. Países com os maiores quantitativos de publicações




Fonte: Elaboração Própria.

4.3 AUTORES MAIS PROLÍFICOS

A análise de autoria identifica os pesquisadores que mais contribuíram com publicações no período. A Figura 4 apresenta os autores com maior número de artigos, evidenciando a formação de grupos de pesquisa consolidados e a liderança de pesquisadores específicos, majoritariamente de afiliação chinesa.

Figura 4. Autores com os maiores quantitativos de publicações



Fonte: Elaboração Própria.

4.4 FOCOS TEMÁTICOS DA PESQUISA

A análise de frequência das palavras-chave fornecidas pelos autores revela os temas centrais que dominam a literatura. Os termos mais recorrentes foram:

- **deep learning** – 507 ocorrências;
- **skin cancer** – 286 ocorrências;
- **artificial intelligence** – 285 ocorrências;
- **melanoma** – 232 ocorrências;
- **dermatology** – 170 ocorrências.

Essa recorrência indica um forte direcionamento da pesquisa para o uso de técnicas de aprendizado profundo na detecção de câncer de pele, especialmente o melanoma.

5 DISCUSSÃO

Os resultados bibliométricos apresentados revelam tendências marcantes que merecem uma análise aprofundada. Mais do que números, eles refletem a trajetória de maturidade do campo, suas implicações geográficas e os focos temáticos que moldam o futuro da IA na dermatologia.

5.1 A CURVA DE MATURIDADE

O crescimento exponencial de publicações até 2024 não é um fenômeno isolado. Ele coincide com a democratização de ferramentas de *deep learning* (como *TensorFlow* e *PyTorch*) e, crucialmente, com a disponibilização de grandes conjuntos de dados públicos, como os desafios da *International Skin Imaging Collaboration* (ISIC). Esses fatores permitiram que pesquisadores em todo o mundo validassem e desenvolvessem novos modelos, gerando uma onda de estudos "prova de conceito".

A aparente estabilização em 2025 pode sinalizar uma transição importante: o campo pode estar se movendo de questões como "*É possível a IA diagnosticar lesões de pele?*" para desafios de segunda geração, mais complexos e aplicados: "*Como integrar essa IA de forma segura, ética e eficaz no ambiente clínico?*".



Isso se alinha com a crescente preocupação na literatura sobre viés algorítmico, explicabilidade (XAI) e a necessidade de validação em ensaios clínicos prospectivos, como apontado na introdução.

5.2 IMPLICAÇÕES DA CONCENTRAÇÃO GEOGRÁFICA

A dominância de China, Estados Unidos e Índia (Figura 3) demonstra como políticas de incentivo à P&D em IA se traduzem em liderança científica. No entanto, essa concentração geográfica levanta questões sociais e éticas críticas. A principal delas é o risco de perpetuar o viés nos dados de treinamento. Se os algoritmos são majoritariamente desenvolvidos e treinados com dados de populações asiáticas e caucasianas, sua acurácia tende a diminuir drasticamente em tons de pele sub-representados, como os de populações africanas e latino-americanas.

Este cenário cria um paradoxo: a tecnologia com potencial para democratizar o acesso ao diagnóstico pode, na verdade, aprofundar as desigualdades em saúde se não houver um esforço consciente para a construção de bancos de dados globais e representativos. A liderança quantitativa de poucos países, portanto, deve ser um alerta para a necessidade de fomentar colaborações internacionais mais inclusivas.

5.3 O FOCO EM CÂNCER DE PELE

O foco da pesquisa em "skin cancer" e "melanoma" é justificado pela gravidade da doença e pelo sucesso da IA em alcançar alta precisão diagnóstica. Contudo, essa concentração ofusca outras doenças de pele comuns, como psoríase e eczema, que, embora menos letais, afetam a qualidade de vida de muitas pessoas. A pesquisa nessas áreas é menos robusta, representando uma clara lacuna e uma grande oportunidade para futuras aplicações da IA.

6 CONCLUSÃO E PERSPECTIVAS FUTURAS

6.1 CONCLUSÃO

Esta análise bibliométrica mapeou a ascensão da inteligência artificial na dermatologia entre 2015 e 2025, revelando um campo de pesquisa em plena expansão, mas também concentrado geograficamente e tematicamente. O crescimento foi impulsionado pela maturidade do *deep learning* e pela disponibilidade de dados, com um foco predominante no diagnóstico de câncer de pele. A liderança de China, EUA e Índia destaca o papel do investimento estratégico, mas também levanta preocupações sobre a diversidade e a equidade no desenvolvimento tecnológico. O campo parece estar em um ponto de inflexão, migrando de estudos de viabilidade para a busca por uma implementação clínica responsável.

6.2 LIMITAÇÕES DO ESTUDO

É importante reconhecer as limitações deste trabalho. A busca restrita a artigos em inglês pode ter sub-representado a produção científica de regiões não anglófonas. Adicionalmente, a utilização exclusiva das bases Scopus e Web of Science, embora abrangentes, pode ter omitido trabalhos relevantes indexados em plataformas mais específicas da área médica (como PubMed) ou da engenharia (como IEEE Xplore). Essa escolha metodológica pode ter influenciado os contornos dos resultados geográficos e temáticos aqui apresentados.

6.3 PERSPECTIVAS PARA PESQUISAS FUTURAS

Para o futuro, a pesquisa em IA na dermatologia precisa focar em tornar a tecnologia prática, justa e segura. As direções principais são:

1. **Testes no Mundo Real:** Sair dos laboratórios e realizar estudos clínicos para ver se a IA realmente melhora o diagnóstico e o tratamento de pacientes.
2. **Corrigir o Viés:** Criar ativamente algoritmos que funcionem bem em todos os tons de pele, desenvolvendo bancos de dados mais inclusivos.



3. **Foco no Uso Médico:** Pesquisar como os médicos interagem com a IA para criar ferramentas fáceis de usar e que ajudem, sem substituir, o julgamento profissional.
4. **Análise Ampla:** Entender como diferentes áreas (medicina, engenharia) veem o problema para ter uma visão mais completa.

Em suma, o objetivo é transformar a tecnologia em benefícios concretos e equitativos para todos os pacientes.

AGRADECIMENTOS

Ao Instituto Federal da Bahia (IFBA), Campus Salvador, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e ao Colegiado do Mestrado em Engenharia de Sistema e Produtos (PPGESP/IFBA).

REFERÊNCIAS

ABBAS Q., CELEBI M. E., GARCIA I. F. A comprehensive review of recent advances in skin lesion analysis using deep learning techniques. IEEE Access. 2022;10:12245-71.

AMANN J., BLASIMME A., VAYENA E., FREY D., MADAI V. I. Explainability for artificial intelligence in healthcare: a multidisciplinary perspective. BMC Med Inform Decis Mak. 2022;22(1):1-19.

BEHARA N., et al. AI in dermatology: a comprehensive review into skin cancer detection. PubMed. 2024.

BISSOTO A., FORNACIALI M., VALLE E., AVILA S. (Dis)Advantages of synthetic data: Assessing the impact of real and fake images on deep learning models for skin lesion classification. arXiv Preprint. 2019;arXiv:1904.08818.

CARCAGNÌ P., DEL COCO M., LEO M., DISTANTE C. Skin lesion classification using deep learning and image processing. Proc 14th Int Conf Signal-Image Technol Internet-Based Syst. 2018:16-23.

CHATTERJEE S., MAJUMDAR A., DUTT A., MAJUMDER S. A deep learning based multi-class skin lesion classification approach using mobile-based dermoscopy images. Biomed Signal Process Control. 2022;73:103426.

CHOY B., CHENG K., LEE V., WONG J., et al. Deep learning models across the range of skin diseases: A comprehensive review. Clin Mol Skin Investig. 2024;11(1):24-38.

DANESHJOU R., VODRAHALLI K., NOVOA R. A., et al. Disparities in dermatology AI performance on a diverse, curated clinical image set. arXiv Preprint. 2022;arXiv:2203.08807.

ESTEVA A., KUPREL B., NOVOA R. A., KO J., SWETTER S. M., BLAU H. M., THRUN S. Dermatologist-level classification of skin cancer with deep neural networks. Nature. 2017;542(7639):115-8.

FARHUD D. D., ZOKAEI S. Ethical Issues of Artificial Intelligence in Medicine and Healthcare. Iran J Public Health. 2021 Nov;50(11):i-v.

HEINLEIN L., MARON R. C., et al. Prospective multicenter study using artificial intelligence to improve dermoscopic melanoma diagnosis in patient care. Commun Med. 2024 Sep 11;4(1):177.



JAIN S., SINGHANIA U., TRIPATHY B., NASR E. A., ABOUDAIF M. K., KAMRANI A. K. Deep Learning-Based Transfer Learning for Classification of Skin Cancer. *Sensors*. 2021;21(23):8142.

KHETERPAL V., LIU Y., CARIN L. Artificial intelligence in dermatology: current applications, opportunities, and limitations. *J Am Acad Dermatol*. 2022;86(5):1240-50.

KIM D., et al. Lightweight deep learning models for mobile-based melanoma detection. *J Mob Health*. 2023;9(1):13-24.

KITTLER H., PEHAMBERGER H., et al. The effect of machine learning assistance on the accuracy of dermatologists in the diagnosis of skin lesions: a randomized controlled trial. *J Investig Dermatol*. 2020;140(3):547-53.

KOUSIS I., PERIKOS I., HATZILYGEROUDIS I., VIRVOU M. Deep Learning Methods for Accurate Skin Cancer Recognition and Mobile Application. *Electronics*. 2022;11(9):1294.

MELAFIND STUDY GROUP. Evaluation of MelaFind: a non-invasive computer vision system for melanoma detection. *J Am Acad Dermatol*. 2011;65(4):639-48.

OZDEMIR B., PACAL I. A robust deep learning framework for multiclass skin cancer classification. *Sci Rep*. 2025;15(1):4938.

REZVANTALAB A., SAFIGHOLI H., KARIMIJESHNI S. Dermatologist level dermoscopy skin cancer classification using different deep learning convolutional neural networks algorithms. *arXiv Preprint*. 2018;arXiv:1810.10348.

SHORTLIFFE E. H., BUCHANAN B. G., FEIGENBAUM E. A. *Computer-based medical consultations: MYCIN*. Elsevier. 1970.

SONI T., GUPTA S., ALMOGREN A., ALTAMEEM A., REHMAN A. U., HUSSEN S., BHARANY S. ARCUNet: enhancing skin lesion segmentation with residual convolutions and attention mechanisms for improved accuracy and robustness. *Sci Rep*. 2025 Mar 18;15(1):94380-9.

WAGNER M., et al. Clinical application of the FotoFinder Moleanalyzer pro: diagnostic performance and utility. *J Dermatol Treat*. 2021;32(3):333-40.

WASHINGTON POST. AI is coming to skin cancer detection. *Washington Post Health Section*. 2025 Apr.

WU Y., CHEN B., ZENG A., PAN D., WANG R., ZHAO S. Skin Cancer Classification With Deep Learning: A Systematic Review. *Front Oncol*. 2022 Jul 13;12:893972.