



CAPÍTULO 10

SISTEMA DE APOIO À DECISÃO CLÍNICA EM MAMOGRAFIA DIGITAL USANDO INTELIGÊNCIA ARTIFICIAL

 <https://doi.org/10.22533/at.ed.3421425201110>

David Lopes Maciel

Master in Master of Science in Emergent Technologies in Education.
MUST UNIVERSITY, MUST, EUA, Academic of the Doctoral Program in
Regional Development and Environment (PGDRA/UNIR).

Natiele Vieira de Oliveira Maciel

Especialista em Oncologia - Centro Universitário (UNINTER),
Especialista em Saúde da Família – IFAM

Fábricio Moraes de Almeida

PhD in Physics (UFC), with post-doctorate (DCR/CNPq). Specialist in Software
Engineering/Systems Analysis and Development (UniUnica). Researcher of the Doctoral
and Master Program in Regional Development and Environment (PGDRA/UNIR).

RESUMO: Este capítulo de livro, demonstra o desenvolvimento e a validação de um sistema de apoio à decisão clínica voltado para a triagem de mamografias digitais usando Inteligência Artificial. A proposta integra redes neurais convolucionais (CNNs) com lógica fuzzy, combinando a alta capacidade discriminativa de modelos de aprendizado profundo com a interpretabilidade fornecida por sistemas baseados em regras linguísticas. Alguns estudos recentes demonstram que a integração de sistemas fuzzy com modelos de aprendizado de máquina oferece ganhos relevantes em precisão e acurácia diagnóstica, particularmente em contextos clínicos de alta variabilidade. Utilizando um banco de dados abertos de imagens reais oriundas de instituições brasileiras, o sistema foi treinado em uma arquitetura convolucional otimizada para tarefas médicas, processando imagens DICOM convertidas e normalizadas. Cada imagem gera um vetor de ativação que é posteriormente analisado por um módulo fuzzy, responsável por produzir inferências clínicas contínuas e explicáveis. Os resultados obtidos demonstram que essa abordagem

integrada amplia a sensibilidade diagnóstica e melhora a generalização do modelo, sobretudo em cenários com dados incompletos como exames compostos por uma ou duas imagens. Dessa forma, a comparação com modelos puramente de redes neurais evidencia ganhos relevantes, posicionando a solução como alternativa promissora para ambientes clínicos que exigem rastreamento confiável e auditável, com acurácia e precisão maximizadas.

PALAVRAS-CHAVE: Diagnóstico. Mamografia digital. Inteligência Artificial. RNC.

Clinical Decision Support System in Digital Mammography Using Artificial Intelligence

ABSTRACT: This book chapter demonstrates the development and validation of a clinical decision support system for digital mammography screening using Artificial Intelligence. The proposed method integrates convolutional neural networks (CNNs) with fuzzy logic, combining the high discriminative capacity of deep learning models with the interpretability provided by rule-based inference systems. Recent studies have shown that the integration of fuzzy systems with machine learning models leads to significant improvements in diagnostic precision, particularly in clinical contexts characterized by high variability. Trained on real-world imaging data from Brazilian institutions, the system employs a convolutional architecture optimized for medical imaging tasks, processing standardized and normalized DICOM images. Each image yields an activation vector that is subsequently analyzed by a fuzzy module responsible for generating continuous and interpretable clinical inferences. The results indicate that this integrated approach enhances diagnostic sensitivity and improves model generalization, especially in cases involving incomplete data such as studies composed of only one or two images. Thus, comparison with purely neural network models reveals significant gains, positioning the solution as a promising alternative for clinical environments that require reliable and auditable tracking, with maximized accuracy and precision.

KEYWORDS: Diagnosis. Digital Mammography. AI. CNN.

INTRODUÇÃO

Atualmente, é evidente que a Medicina está sendo impulsionada pelo desenvolvimento tecnológico, especialmente no diagnóstico e no tratamento. A tecnologia, incluindo a Inteligência Artificial, as teleconsultas e os dispositivos

médicos, otimizam e transformam a entrega de cuidados de saúde, proporcionando maior acurácia e eficiência no diagnóstico e no tratamento (COSTA et al. 2024).

O câncer de mama é uma das principais causas de mortalidade entre mulheres no Brasil, gerando impactos substanciais sobre os sistemas de saúde pública e os serviços de atenção oncológica. De acordo com estimativas atualizadas do Instituto Nacional de Câncer (INCA), mais de 73 mil novos casos são diagnosticados anualmente no país, o que reforça a necessidade de estratégias de rastreamento que sejam, ao mesmo tempo, eficazes, acessíveis e clinicamente interpretáveis (INCA, 2024).

Destarte, a mamografia digital permanece como o principal exame de rastreamento populacional para detecção precoce do câncer de mama, reconhecida por sua elevada acurácia na identificação de lesões suspeitas. No entanto, sua eficácia está diretamente associada à qualidade das imagens adquiridas, à experiência do profissional responsável pela leitura e à conhecida variabilidade interobservador. Nesse contexto, sistemas automatizados baseados em inteligência artificial (IA) têm se destacado como ferramentas complementares promissoras, capazes de reduzir o viés subjetivo e padronizar o processo decisório. Apesar disso, muitos desses sistemas ainda funcionam como estruturas opacas verdadeiras “caixas-pretas”, dificultando sua aceitação por parte da comunidade médica e limitando sua adoção em ambientes clínicos reais.

Diante desse cenário, ganha relevância a adoção de abordagens híbridas que aliam a elevada capacidade preditiva das redes neurais profundas à transparência interpretativa de sistemas baseados em lógica simbólica. A lógica fuzzy, em particular, destaca-se como uma alternativa eficaz por sua habilidade em representar incertezas e traduzir informações quantitativas em regras linguísticas comprehensíveis, oferecendo uma interface mais intuitiva entre os algoritmos e os profissionais de saúde. Essa combinação favorece o desenvolvimento de modelos de IA mais explicáveis, auditáveis e aderentes às exigências éticas e operacionais da prática clínica (IQBAL, 2024).

Portanto, este estudo propõe e valida um sistema de apoio à decisão clínica em mamografia digital, estruturado a partir da integração entre redes neurais convolucionais (CNNs) e lógica fuzzy. A Modelagem de Sistema de IA foi desenvolvida com base em imagens provenientes de instituições brasileiras, contemplando a diversidade de condições presentes na prática clínica nacional. A avaliação foi conduzida em cenários realistas, incluindo exames com diferentes quantidades de imagens por paciente — uma característica comum em fluxos clínicos reais que frequentemente envolvem registros assimétricos ou incompletos. Ao conjugar desempenho técnico com interpretabilidade, a proposta busca fomentar a adoção de soluções de inteligência artificial explicável, em conformidade com os princípios

de segurança, transparência e aplicabilidade exigidos na saúde pública (RIBEIRO et al., 2016).

METODOLOGIA E TÉCNICAS DE PESQUISA USANDO IA.

Engenharia de Dados - Aquisição e Pré-processamento das Imagens

A base de dados utilizada neste estudo é composta por exames de mamografia digital de rastreamento obtidos em instituições brasileiras, disponibilizados publicamente por meio de uma iniciativa de compartilhamento científico da Sociedade Paulista de Radiologia (SPR). Os dados refletem a diversidade de padrões anatômicos, técnicas de aquisição e condições operacionais típicas da prática clínica nacional. Cada exame está vinculado a um único paciente e pode conter de uma até mais de quatro imagens, evidenciando variações decorrentes de protocolos institucionais e da completude dos registros armazenados (SPR, 2025).

As imagens foram disponibilizadas originalmente no formato DICOM (.dcm), contendo não apenas os dados visuais, mas também metadados clínicos relevantes para o contexto diagnóstico. A fim de viabilizar o treinamento eficiente do modelo de inteligência artificial, essas imagens passaram por um processo de conversão para o formato PNG, com padronização em escala de cinza (um único canal) e resolução uniforme de 224x224 pixels. Esse procedimento foi realizado por meio de rotinas automatizadas implementadas com o uso das bibliotecas pydicom e OpenCV, amplamente adotadas em aplicações de processamento de imagens médicas.

Durante o processo de conversão, foi implementada uma correção automática da fotometria com o objetivo de padronizar as representações MONOCHROME1 e MONOCHROME2, realizando a inversão de brilho sempre que necessário para garantir a uniformidade visual entre os exames. Após essa etapa, todas as imagens foram normalizadas e organizadas por estudo individual (com base no identificador do paciente), possibilitando a construção de tensores estruturados no formato [N, 1, 224, 224], onde N corresponde à quantidade de imagens disponíveis para cada paciente. Essa padronização é essencial, pois, conforme especificado no padrão DICOM, as interpretações fotométricas MONOCHROME1 e MONOCHROME2 determinam diferentes representações de brilho, sendo necessário ajustá-las para garantir a consistência na visualização e análise das imagens (DICOM Standard, 2024).

Optou-se deliberadamente por manter, no conjunto de dados, exames com menos de quatro imagens por paciente, a fim de preservar a representatividade dos casos clínicos reais. Essa decisão está alinhada ao propósito central deste estudo, que é desenvolver uma arquitetura capaz de operar em condições adversas e assimétricas de entrada cenário comum em serviços de diagnóstico por imagem, especialmente

no contexto do SUS. Ao permitir que o modelo processe estudos incompletos, impõe-se à rede neural e ao sistema fuzzy o desafio de produzir inferências robustas mesmo diante de limitações de dados, conforme também discutido por Al-Qaysi et al. (2023), que destacam o papel de modelos híbridos em cenários com estruturas de entrada variáveis e parciais.

2.2 Arquitetura de Rede Neural

Para o núcleo de aprendizado profundo, foi adotada uma arquitetura derivada da ResNet, amplamente reconhecida por sua eficácia em tarefas de classificação de imagens complexas. A escolha se justifica pela capacidade dos blocos residuais em mitigar o problema do desaparecimento do gradiente e em permitir a aprendizagem de representações profundas e estáveis (HE et al., 2016). A adaptação envolveu ajustes para compatibilizar o modelo com entradas em escala de cinza, características da mamografia digital, e refinar sua sensibilidade a estruturas morfológicas sutis, frequentemente presentes em exames mamários.

A implementação do modelo foi realizada na estrutura PyTorch, utilizando pesos pré-treinados na base ImageNet como ponto de partida. Essa estratégia de transferência de aprendizado foi fundamental para acelerar a convergência do treinamento e melhorar o desempenho do modelo diante de uma base com características específicas da realidade clínica brasileira.

Após o processamento de cada imagem, a rede gera um vetor de ativação de dimensão reduzida extraído da penúltima camada totalmente conectada, imediatamente anterior à camada softmax final que sintetiza as principais características morfológicas capturadas, servindo como representação numérica para as etapas posteriores de inferência. Estudos demonstram que modelos pré-treinados no ImageNet, quando ajustados para tarefas médicas específicas, podem melhorar significativamente o desempenho em análises de imagens médicas (HOSSEINZADEH TAHER et al., 2021).

Os vetores de ativação gerados pela rede convolucional são posteriormente utilizados como entrada para o módulo fuzzy. Além dessa função, podem ser interpretados como embeddings latentes que sintetizam aspectos morfológicos relevantes de cada imagem mamográfica. Nos casos em que o exame de um paciente inclui múltiplas imagens, esses vetores são combinados por meio de uma média aritmética ponderada, resultando em uma representação vetorial única por estudo, capaz de capturar, de forma condensada, as informações discriminativas distribuídas entre as diferentes incidências.

Durante o treinamento da rede convolucional, foi adotada a função de perda de entropia cruzada binária, amplamente utilizada em tarefas de classificação binária com saídas probabilísticas. O processo de otimização foi conduzido com

o algoritmo Adam, configurado com uma taxa de aprendizado inicial dinâmica, ajustada automaticamente por um agendador exponencial ao longo das épocas.

Considerando o desbalanceamento da base de dados com predomínio de exames classificados como normais — foram aplicadas estratégias de ponderação de classes na própria função de perda. Essa abordagem teve como objetivo ampliar a penalização para falsos negativos, priorizando a sensibilidade do modelo em cenários clínicos críticos (SUN et al., 2024).

Figura 1. Arquitetura do sistema híbrido proposto. As imagens mamográficas são processadas por uma rede convolucional (ResNet adaptada), que gera vetores de ativação interpretados por um sistema fuzzy multicamada baseado em regras linguísticas. O resultado final é uma saída contínua interpretável, associada a uma decisão clínica binária (Recall / Normal).

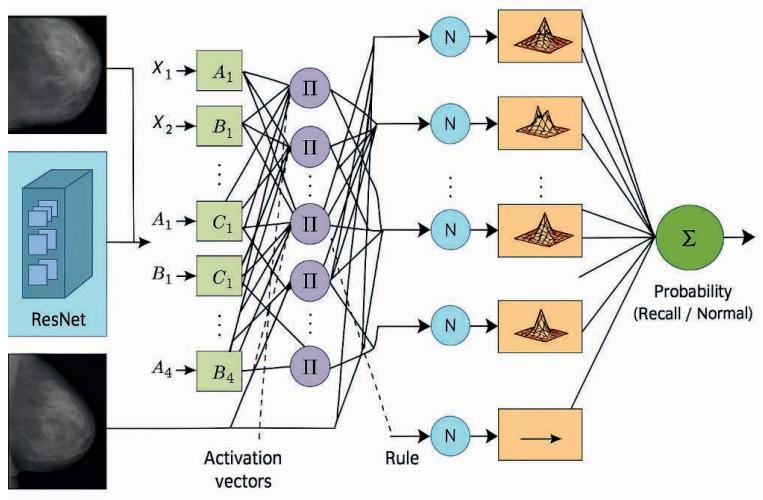


Figura 1 - Fluxograma para uso de Inteligência Artificial.

Fonte: Autor,2025

A seguir, será descrito o módulo fuzzy responsável pela inferência linguística sobre os vetores gerados pela CNN.

Desenvolvimento do Sistema Fuzzy: Regras Linguísticas e Inferência

O módulo fuzzy foi concebido para operar como uma camada adicional de inferência simbólica aplicada aos vetores de ativação extraídos pela rede neural convolucional. Sua principal função é ampliar a interpretabilidade do sistema, fornecendo explicações linguísticas e aumentando a robustez da tomada de decisão

clínica. A lógica fuzzy é particularmente eficaz em contextos marcados por incertezas ou dados parciais, como ocorre frequentemente em exames com número reduzido de imagens, nos quais o raciocínio tradicional baseado apenas em aprendizado profundo pode se tornar instável ou opaco do ponto de vista clínico.

A entrada do sistema fuzzy consiste no vetor médio de ativação gerado por estudo, previamente normalizado. Esse vetor representa uma síntese das características morfológicas extraídas pela rede neural convolucional a partir das imagens de mamografia digital.

No contexto deste trabalho, os estudos clínicos analisados correspondem a exames reais provenientes de instituições brasileiras, frequentemente compostos por um número reduzido de imagens por paciente — uma condição comum na prática diagnóstica, especialmente em unidades de triagem e rastreamento. A modelagem fuzzy foi estruturada em três etapas principais, envolvendo a transformação das ativações em categorias linguísticas, a aplicação de regras de inferência e, por fim, a geração de uma saída contínua interpretável, compatível com a lógica clínica.

(a) Fuzzificação:

Na primeira etapa do sistema, cada componente do vetor de entrada é mapeado para conjuntos difusos por meio de funções de pertinência do tipo triangular e trapezoidal, definidas com base na distribuição estatística dos valores de ativação observados durante o treinamento. Esses conjuntos representam categorias linguísticas como baixo, médio e alto grau de ativação, permitindo traduzir a intensidade de resposta da rede neural em termos comprehensíveis sob a ótica clínica. Essa transformação simbólica facilita a interpretação dos padrões captados nas imagens e estabelece a base para a inferência fuzzy subsequente.

(b) Base de Regras Linguísticas:

A etapa de inferência é conduzida por um conjunto estruturado de regras linguísticas do tipo “SE o grau de ativação for alto EM ALGUM dos componentes, ENTÃO o risco de recall é elevado”. Ao todo, foram definidas nove regras principais, elaboradas em conjunto com profissionais da área médica e refinadas com base em testes de sensibilidade sobre os dados de treinamento. A lógica adotada prioriza a detecção de qualquer padrão suspeito, mesmo que isolado, utilizando operadores do tipo OR entre os elementos do vetor. Essa abordagem está em consonância com a conduta clínica de triagem, na qual a sensibilidade deve ser maximizada para evitar a omissão de casos suspeitos.

(c) Inferência e Defuzzificação:

As regras linguísticas são processadas por meio do mecanismo de inferência Mamdani, utilizando operadores de agregação do tipo máximo para combinar

os resultados parciais. O sistema produz, como saída intermediária, um grau de confiança fuzzy associado a uma das duas classes: recall necessário ou exame normal. Em seguida, essa saída contínua é convertida para um valor escalar por meio do método do centro de massa (centroide), conhecido como defuzzificação por média ponderada.

O valor final é interpretado como uma probabilidade clínica, compatível com modelos binários de decisão, permitindo integração direta com fluxos computacionais utilizados em triagem automatizada. Essa abordagem é comum em sistemas de fusão de imagens médicas, onde a inferência Mamdani e a defuzzificação por centroide são aplicadas para combinar informações de múltiplas modalidades de imagem, melhorando a precisão diagnóstica (RAO et al., 2024).

A camada fuzzy atua como um filtro interpretativo sobre a saída gerada pela rede neural, conferindo ao sistema a capacidade de fornecer não apenas uma classificação binária, mas também um grau de confiança expresso em termos linguísticos. Esse diferencial representa um avanço importante para a integração de modelos de inteligência artificial em ambientes clínicos reais, especialmente naqueles que exigem rastreamento transparente e auditável das decisões automatizadas. Ao associar cada predição a uma justificativa interpretável, o sistema contribui para a construção de confiança por parte dos profissionais da saúde e amplia o potencial de adoção da ferramenta em contextos de triagem mamográfica assistida.

ANÁLISES DOS RESULTADOS E DISCUSSÃO

Protocolo de Avaliação

Para avaliar o desempenho do sistema proposto, adotou-se uma estratégia de validação cruzada estratificada, com o objetivo de preservar a distribuição original das classes (exames classificados como recall e normal) ao longo dos subconjuntos de dados. A base foi dividida em três partes: 70% para o treinamento do modelo, 15% para validação e 15% para teste.

Como medida de controle, todos os exames pertencentes a um mesmo paciente foram alocados exclusivamente em um único subconjunto, evitando qualquer tipo de vazamento de informação entre as diferentes fases do processo de aprendizado. Essa abordagem é recomendada para evitar o sobreajuste e garantir uma estimativa mais precisa do desempenho do modelo em dados não vistos (BRADSHAW et al., 2023).

A performance do sistema foi analisada sob dois cenários: Cenário I: Avaliação do modelo CNN puro, sem o módulo fuzzy e o Cenário II: Avaliação do sistema híbrido CNN + Fuzzy.

Métricas Utilizadas

As métricas adotadas seguem padrões estabelecidos em sistemas de apoio à decisão clínica: (i) Sensibilidade (Recall): capacidade de identificar corretamente os casos positivos (exames que requerem recall); (ii) Especificidade: capacidade de identificar corretamente os casos negativos; (iii) Acurácia: proporção de predições corretas no total de exames. (iv) AUC-ROC: área sob a curva ROC, refletindo a capacidade discriminativa geral e (v) F1-Score: média harmônica entre precisão e sensibilidade, relevante em bases desbalanceadas.

Análise e a Comparação dos Resultados

A Tabela 1 apresenta um resumo comparativo do desempenho obtido nos dois cenários analisados: o modelo baseado exclusivamente em CNN e a versão híbrida que incorpora o módulo fuzzy.

Modelo	Sensibilidade	Especificidade	Acurácia	AUC-ROC	F1-Score
CNN Pura	0.81	0.77	0.79	0.85	0.78
CNN + Fuzzy (Proposto)	0.87	0.74	0.81	0.88	0.82

Tabela 1- Análise da performance nos cenários I e II.

Fonte: autor, 2025

Dessa forma, os resultados indicam que a integração da lógica fuzzy ao pipeline de inferência contribuiu para um aumento significativo da sensibilidade e do F1-Score, mesmo com uma ligeira redução na especificidade. Essa compensação é considerada aceitável e até desejável no contexto de sistemas de triagem, nos quais a prioridade clínica recai sobre a detecção precoce de alterações suspeitas. Assim, a ocorrência de *overall* é preferível à possibilidade de *missed detection*, reforçando o potencial da abordagem híbrida como ferramenta auxiliar segura em ambientes clínicos.

Figura 2. Comparação das métricas clínicas entre o modelo CNN puro e o sistema híbrido CNN + Fuzzy. Observa-se aumento de sensibilidade e F1-Score com leve redução na especificidade comportamento esperado e desejável em sistemas de triagem com prioridade em detecção precoce.

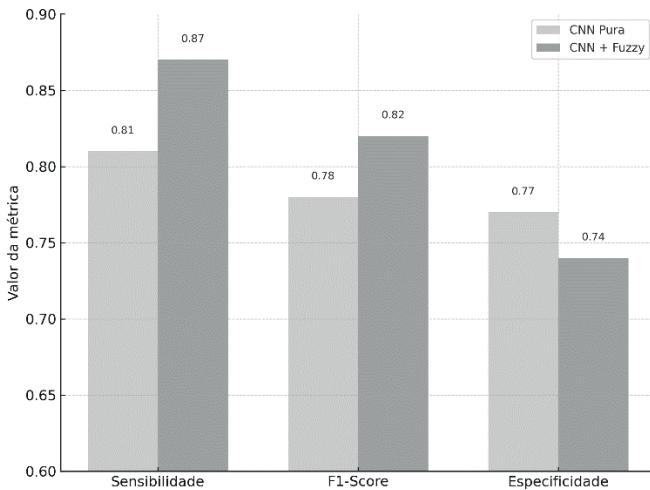


Figura 2 – IA: lógica fuzzy nas métricas clínicas.

Fonte: Autor,2025

De fato, durante a etapa de processamento, foram analisados 15.106 estudos, totalizando 97.623 imagens DICOM convertidas. Dentre esses, 8.620 estudos apresentavam exatamente quatro imagens, enquanto 3.760 tinham menos de quatro e 2.726 apresentavam mais do que quatro imagens por paciente. Após a conversão e organização dos dados, foram gerados 10.574 tensores utilizados para o treinamento do modelo, 2.260 tensores alocados para validação e 2.272 para a fase de teste final.

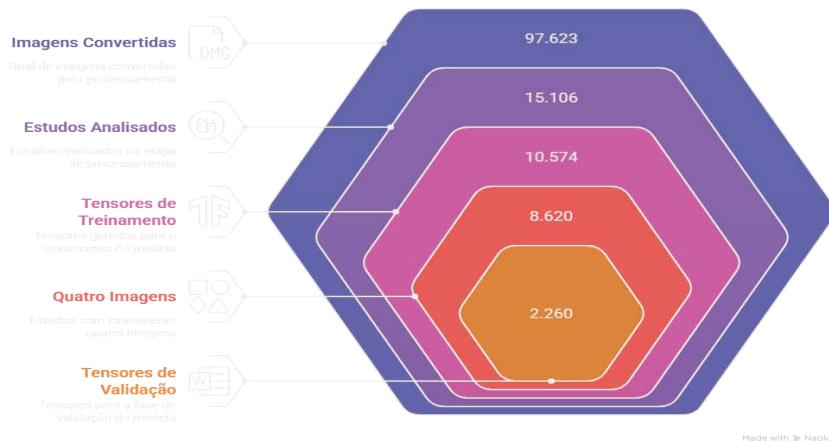


Figura 3 – Esquema do pipeline de engenharia de dados.

Fonte: autor, 2025

Análise Qualitativa de Casos-Limite

Exames compostos por apenas uma ou duas imagens condição recorrente na base brasileira analisada mostraram-se especialmente favorecidos pela abordagem híbrida. Nessas situações, o modelo baseado exclusivamente em CNN apresentou maior variabilidade e instabilidade na inferência, com tendência a classificações inconsistentes.

A introdução da camada fuzzy atuou como um mecanismo regulador, absorvendo flutuações nos vetores de ativação e compensando ativações espúrias, o que resultou em decisões mais coerentes com o contexto clínico. Essa integração entre CNN e lógica fuzzy tem se mostrado eficaz em outras aplicações médicas, como na detecção e classificação automática de objetos em imagens de ensaio cometa, onde o modelo híbrido FIS-CNN demonstrou alta precisão e robustez (AL-QAYSI; GUNGORMUS, 2023).

Observou-se, em diferentes casos clínicos com estrutura de entrada reduzida, que o sistema híbrido foi capaz de corrigir classificações equivocadas geradas pela CNN isolada. Esses episódios reforçam o papel da camada fuzzy como um componente interpretativo e contextual, capaz de agregar valor semântico às predições do modelo e ajustar decisões com base em padrões linguísticos compatíveis com a lógica médica.

Durante a execução do estudo, foram utilizados dados provenientes de exames de mamografia digital de rastreamento, realizados em serviços brasileiros de saúde. Cada estudo corresponde a um paciente único e pode conter de uma a mais de quatro imagens, refletindo a variabilidade observada na prática clínica, tanto em termos de protocolos de aquisição quanto da completude dos registros. As imagens, originalmente no formato DICOM, passaram por um processo de conversão e normalização, assegurando a consistência necessária para o treinamento e avaliação dos modelos, sem perder a fidelidade às condições reais dos fluxos de triagem mamográfica.

CONCLUSÃO E PERSPECTIVAS FUTURAS

Este capítulo de livro apresentou o desenvolvimento e a validação de sistema híbrido de apoio à decisão clínica em mamografia digital, combinando redes neurais convolucionais (CNNs) com lógica fuzzy para a triagem automatizada de exames que requerem recall. O modelo foi treinado e testado com banco de dados abertos de instituições brasileiras, refletindo a diversidade e os desafios da prática clínica nacional, incluindo casos com número variável de imagens por paciente.

De fato, a integração entre aprendizado profundo e inferência simbólica demonstrou ganhos significativos em sensibilidade e robustez diagnóstica, especialmente em cenários clínicos críticos como exames incompletos ou com baixa qualidade. Com a adição de uma camada fuzzy baseada em regras linguísticas, o sistema tornou-se não apenas mais preciso, mas também mais interpretável, o que favorece sua integração em ambientes hospitalares que exigem rastreamento auditável das decisões automatizadas.

O desenvolvimento do sistema híbrido está convergindo para tendências atuais na área de inteligência artificial aplicada à saúde, que buscam combinar a capacidade de extração automática de características do deep learning com o raciocínio lógico e a interpretabilidade da inteligência artificial simbólica, resultando em sistemas mais transparentes e confiáveis para aplicações clínicas críticas (MUSANGA et al., 2025).

De forma geral, o modelo contribui para o avanço da inteligência artificial explicável (XAI) aplicada à saúde, ao propor uma abordagem que respeita tanto os critérios de desempenho computacional quanto os requisitos de transparência clínica. A lógica fuzzy funciona como um elo entre os padrões de ativação gerados pela CNN e o raciocínio médico, favorecendo a compreensão e a aceitação do sistema por parte dos profissionais de saúde.

Como perspectivas futuras, pretende-se expandir o conjunto de dados com a inclusão de instituições de diferentes regiões do Brasil, com o objetivo de ampliar a capacidade de generalização do modelo. Também está prevista a incorporação de

metadados clínicos, como idade, histórico familiar e achados anteriores à entrada fuzzy, visando enriquecer o raciocínio baseado em conhecimento contextual. Além disso, propõe-se a integração do sistema em plataformas web e ambientes PACS hospitalares, facilitando sua validação em cenários clínicos reais. Por fim, planeja-se a realização de estudos clínicos prospectivos para avaliar o impacto como ferramenta na rotina de trabalho radiológico e nas taxas de detecção precoce do câncer de mama.

Por fim, espera-se que análise e o desenvolvimento do sistema de IA da proposta contribua para otimização de ferramentas inteligentes de rastreamento, fortalecendo a atuação preventiva da atenção primária em saúde e apoiando políticas públicas voltadas ao enfrentamento do câncer de mama no Brasil.

REFERÊNCIAS

COSTA, P. G.; SINIS, A. D. B.; DIAS, A. V.; FRANÇA, C. A. G.; OUTUBO, E. N. de F.; TEIXEIRA, F. A. R.; RICHTER, I. C. K.; NASCIMENTO, L. R. F.; GOMES, A. C. C. L. Aplicação de Inteligência Artificial em diagnóstico médico . Brazilian Journal of Health Review, [S. I.], v. 7, n. 3, p. e69616, 2024. DOI: 10.34119/bjhrv7n3-063. Disponível em: <https://ojs.brazilianjournals.com.br/ojs/index.php/BJHR/article/view/69616>. Acesso em: 15 junho 2025.

IQBAL, Saeed. Hybrid Parallel Fuzzy CNN Paradigm: Unmasking Intricacies for Accurate Brain MRI Insights. IEEE Transactions on Fuzzy Systems, 2024. Disponível em: <https://doi.org/10.1109/TFUZZ.2024.3372608>. Acesso em: 19 maio 2025.

INSTITUTO NACIONAL DE CÂNCER (INCA). Estimativa 2024: Incidência de Câncer no Brasil. Rio de Janeiro: Ministério da Saúde, 2024. Disponível em: <https://www.inca.gov.br>. Acesso em: 19 maio 2025.

MOJRIAN, Sanaz; PINTER, Gergo; JOLOUDARI, Javad Hassannataj; FELDE, Imre; NABIPOUR, Narjes; NADAI, Laszlo; MOSAVI, Amir. Hybrid Machine Learning Model of Extreme Learning Machine Radial Basis Function for Breast Cancer Detection and Diagnosis: A Multilayer Fuzzy Expert System. 2019. Disponível em: <https://arxiv.org/abs/1910.13574>. Acesso em: 19 maio 2025.

RIBEIRO, Marco Tulio; SINGH, Sameer; GUESTRIN, Carlos. "Why Should I Trust You?": Explaining the Predictions of Any Classifier. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM, 2016. p. 1135–1144. Disponível em: <https://doi.org/10.1145/2939672.2939778>. Acesso em: 19 maio 2025.

SOCIEDADE PAULISTA DE RADIOLOGIA E DIAGNÓSTICO POR IMAGEM (SPR). Base pública de exames de mamografia digital para pesquisa científica. São Paulo, 2025. Disponível em: <https://www.spr.org.br>. Acesso em: 19 maio 2025.

DICOM STANDARD. Photometric Interpretation Attribute (0028,0004). Disponível em: <https://dicom.innolitics.com/ciods/rt-dose/image-pixel/00280004>. Acesso em: 19 maio 2025.

AL-QAYSI, Shaymaa; NUMAN, Thamer A. Z.; KADHIM, Samer M. A hybrid Fuzzy Logic and Convolution Neural Network (FIS-CNN) for automatic detection and classification of objects in comet assay images. *Materials Today: Proceedings*, 2023. Disponível em: <https://doi.org/10.1016/j.matpr.2023.05.077>. Acesso em: 19 maio 2025.

HE, Kaiming; ZHANG, Xiangyu; REN, Shaoqing; SUN, Jian. Deep Residual Learning for Image Recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016. p. 770–778. DOI: 10.1109/CVPR.2016.90.

HOSSEINZADEH TAKER, Mohammad Reza; HAGHIGHI, Fatemeh; FENG, Ruibin; GOTWAY, Michael B.; LIANG, Jianming. A Systematic Benchmarking Analysis of Transfer Learning for Medical Image Analysis. *arXiv preprint*, 2021. Disponível em: <https://arxiv.org/abs/2108.05930>. Acesso em: 19 maio 2025.

SUN, Haijing; ZHOU, Wen; YANG, Jiapeng; SHAO, Yichuan; XING, Lei; ZHAO, Qian; ZHANG, Le. An Improved Medical Image Classification Algorithm Based on Adam Optimizer. *Mathematics*, v. 12, n. 16, p. 2509, 2024. Disponível em: <https://doi.org/10.3390/math12162509>. Acesso em: 19 maio 2025.

RAO, K. Sihari; RAMBABU, Ch.; PRASANNA, P. Sri Lakshmi; SIVA, T.; KHAN, P. Shoyab; NAGULU, Sk. Mamdani and Sugeno Fuzzy Inference System Based Multimodal Medical Image Fusion. *International Research Journal of Engineering and Technology (IRJET)*, v. 11, n. 3, p. 997–1002, mar. 2024. Disponível em: <https://www.irjet.net/archives/V11/i3/IRJET-V11I3138.pdf>. Acesso em: 25 maio 2025.

MUSANGA, Vengai; VIRIRI, Serestina; CHIBAYA, Colin. A Framework for Integrating Deep Learning and Symbolic AI Towards an Explainable Hybrid Model for the Detection of COVID-19 Using Computerized Tomography Scans. *Information*, v. 16, n. 3, p. 208, 2025. Disponível em: <https://doi.org/10.3390/info16030208>. Acesso em: 25 maio 2025.

V. COPYRIGHT Direitos autorais: Os autores são os únicos responsáveis pelo material incluso no capítulo.