

Aplicação de modelos de redes neurais de análise de textura na área de microscopia

Raquel Silvério Lopes
UNIOESTE

Foz do Iguaçu, Brasil
raquelsilveriolopes@gmail.com

Claudio Roberto Marquette Mauricio
UNIOESTE

Foz do Iguaçu, Brasil
crmmauricio@gmail.com

Fabiana Frata Furlan Peres
UNIOESTE

Foz do Iguaçu, Brasil
ffrata@gmail.com

Abstract—This article discusses the use of artificial neural networks in texture analysis in medical images, with an emphasis on the detection of malaria-infected cells. The concepts behind how these networks work are presented, as well as the importance of texture for pattern discrimination and classification. The study used the Malaria Cell Images Dataset to compare two approaches: the RADAM model, which uses pre-trained convolutional networks solely as feature extractors combined with an SVM classifier, and the BAMBOO model, based on a ResNet-50 trained on a large image set. Both achieved high performance, with accuracy close to 96%, with BAMBOO presenting fewer critical errors. The conclusion is that both techniques are effective, but the choice should be contextualized: RADAM is better suited for scenarios with limited computational resources, while BAMBOO offers greater reliability in clinical applications.

Keywords—neural networks; texture; microscopy.

Resumo—O artigo aborda o uso de redes neurais artificiais na análise de texturas em imagens médicas, com ênfase na detecção de células infectadas pela malária. São apresentados os conceitos de funcionamento das redes, bem como a importância da textura para discriminação e classificação de padrões. O estudo utilizou o Malaria Cell Images Dataset para comparar duas abordagens: o modelo RADAM, que usa redes convolucionais pré-treinadas apenas como extratoras de características combinadas a um classificador SVM, e o modelo BAMBOO, baseado em uma ResNet-50 treinada em um grande conjunto de imagens. Ambos obtiveram alto desempenho, com acurácia próxima a 96%, sendo que o BAMBOO apresentou menor número de erros críticos. Conclui-se que as duas técnicas são eficazes, mas a escolha deve considerar o contexto: RADAM é mais indicado para cenários com recursos computacionais limitados, enquanto o BAMBOO oferece maior confiabilidade em aplicações clínicas.

Palavras-chave—redes neurais; textura; microscopia.

I. INTRODUÇÃO

De acordo com [1], uma rede neural pode ser entendida como um sistema composto por várias unidades simples de processamento que trabalham em paralelo e de forma distribuída. Essas unidades aprendem com o ambiente por meio da experiência e armazenam esse conhecimento nos chamados pesos sinápticos, de modo semelhante ao funcionamento do cérebro humano.




Fig. 1. Estrutura de uma rede neural. Fonte: [2]

Elas possuem uma estrutura igual a da Figura 1 e funcionam da seguinte forma:

- 1) Camada de entrada: obtém os dados brutos que foram alimentados na rede.
- 2) Camadas ocultas: o desempenho dessas camadas é determinado pelas entradas e pelo relacionamento entre os pesos das conexões. De acordo com [1], os pesos sinápticos são parâmetros que determinam a força e o sentido das conexões entre neurônios artificiais, sendo ajustados durante o aprendizado para armazenar o conhecimento adquirido pela rede. Os pesos entre as unidades de entrada e as ocultas determinam quando uma unidade oculta deve ser ativada.
- 3) Camada de saída: o desempenho da unidade de saída depende da atividade e dos pesos das conexões entre as unidades ocultas e as unidades de saída.

De acordo com [3], existem duas principais abordagens de aprendizagem.

Aprendizagem supervisionada: ocorre quando um sistema aprende com exemplos previamente identificados. Durante o treinamento, ele recebe dados com suas respectivas

classificações, o que o ajuda a reconhecer padrões e a classificar novas informações. Por exemplo, para ensinar o computador a diferenciar maçãs e laranjas, mostramos várias frutas e informamos quais são quais. Depois desse aprendizado, o computador consegue identificar corretamente novas frutas [3].

Aprendizagem não supervisionada: é mais complexa que a supervisionada, pois o sistema precisa identificar, por conta própria, as categorias e características dos dados. Esse processo, chamado de clustering (agrupamento), funciona bem quando os grupos são distintos, mas apresenta dificuldades quando os dados são muito semelhantes. Esse tipo de aprendizagem é utilizado na mineração de dados para encontrar padrões [3].

De acordo com [4], texturas podem ser definidas como padrões visuais complexos compostos por subpadrões que apresentam características como brilho, cor, inclinação e tamanho, sendo capazes de fornecer informações sobre a natureza e a forma tridimensional de um objeto. O autor destaca quatro questões principais para o estudo da textura: a extração de características, que busca descrever numericamente propriedades texturais de uma imagem; a discriminação de textura, voltada para particionar imagens em regiões homogêneas; a classificação de textura, que identifica a qual classe pertencem determinadas regiões (como tecidos normais e anormais); e a forma a partir da textura, cujo objetivo é reconstruir a geometria tridimensional da superfície analisada.

Segundo [5], os médicos, ao analisarem exames de imagem, geralmente se concentram em áreas de maior intensidade em relação ao fundo. Contudo, esse critério pode gerar incertezas, já que determinados órgãos, como o cérebro, as glândulas salivares, o baço e o útero, naturalmente apresentam regiões de alta intensidade, o que pode dificultar a interpretação correta, especialmente em exames do tipo DW-MRI (Diffusion-weighted magnetic resonance imaging).

Para estas análises, as redes neurais têm se destacado como um recurso essencial. Elas não apenas auxiliam na detecção automática de patologias, tornando o diagnóstico mais ágil e preciso, mas também demonstram alta eficiência em tarefas como detecção de objetos, classificação e segmentação de imagens o que as torna indispensáveis em diversas aplicações [6].

Dessa forma, as redes neurais surgem como uma solução promissora para superar os desafios na análise de texturas, oferecendo suporte valioso aos especialistas médicos ao executar tarefas complexas com alto grau de precisão [7].

Um exemplo que demonstra como uma rede neural pode ajudar na detecção de doenças na área médica está na Figura 4: a foto de cima é uma amostra cancerígena e a de baixo, uma amostra saudável. Uma pessoa, a olho nu, teria dificuldade em reconhecer qual é a amostra cancerígena [7].




Fig. 2. Amostras de microscopia de células cancerígenas (cima) e células saudáveis (baixo). Fonte: [7]

Segundo [7], “Às vezes, em uma imagem de microscopia de dois tipos de células, nem o médico consegue ver que uma é cancerígena e a outra não, porque é um dado que está em um nível de muita complexidade ou em uma escala em que o especialista não consegue discernir nada. Porém, esse tipo de inteligência artificial consegue.”

II. MATERIAIS E MÉTODOS

A. Ambiente Computacional

Os experimentos da pesquisa foram realizados em um computador da marca Avell, modelo A70 MOB, que possui como especificações principais uma CPU Intel Core i7 11800H, uma GPU NVIDIA GeForce RTX 3060 com 6 GB de memória dedicada e 16 GB de RAM. O desenvolvimento e a execução dos algoritmos, tanto para o BAMBOO quanto para o RADAM, foram feitos na linguagem de programação Python, utilizando-se a versão 3.12.10. Para assegurar a reprodutibilidade dos resultados, foi empregado o gerenciador de ambientes virtuais venv.

B. Conjunto de Dados

O estudo utilizou o conjunto de dados público “Malaria Cell Images Dataset”, disponível no repositório do NIH (National




Fig. 3. Amostras de esfregaço de sangue periférico de células saudáveis (cima) e células afetadas pela malária (baixo). Fonte: [8]

Library of Medicine). Este dataset é composto por imagens de esfregaço de sangue periférico como pode ser visto Figura 3 e contém duas classes de células, onde cada uma é composta por 13.800 imagens:

Parasitized: Células infectadas com o parasita da malária.

Uninfected: Células saudáveis não infectadas.

A tarefa consiste em um problema de classificação binária, onde as características de textura das imagens celulares são cruciais para a distinção entre as duas classes. O conjunto de dados foi dividido em subconjuntos de treinamento e teste para o desenvolvimento e avaliação dos modelos. [8]

C. Modelos de Análise de Textura

Dois métodos principais para reconhecimento de textura foram comparados neste trabalho: RADAM e BAMBOO.

A seleção dos modelos RADAM e BAMBOO para este estudo foi feita a fim de demonstrar duas abordagens distintas de aprendizado de máquina na análise de imagens. O RADAM representa uma abordagem de extração de características (feature extraction), que se destaca pela eficiência computacional ao utilizar uma rede pré-treinada apenas para gerar descritores de

textura, para serem posteriormente processados por um classificador tradicional. Em oposição, o BAMBOO exemplifica o método de aprendizado de ponta a ponta (end-to-end), no qual uma rede neural profunda aprende a tarefa de classificação diretamente a partir dos dados, aproveitando o conhecimento adquirido de um treinamento em larga escala. Essa escolha permite uma análise comparativa direta entre a eficiência de um extrator de texturas especializado e a capacidade de generalização de um modelo robusto treinado com um volume massivo de imagens.

O RADAM (Randomized Aggregated Encoding of Deep Activation Maps) apresenta uma abordagem eficiente para o reconhecimento de texturas, utilizando Redes Neurais Convolucionais (CNNs) pré-treinadas, como a ConvNeXt-nano, estritamente como extratores de características, eliminando a necessidade de qualquer re-treinamento ou ajuste fino (fine-tuning). O processo inicia com a passagem de uma imagem por uma rede neural base, da qual se extrai uma lista de mapas de ativação de diferentes profundidades da arquitetura. Essas ativações, que capturam características da imagem em múltiplos níveis de abstração, são então processadas pelo módulo RADAM. Primeiramente, cada mapa de ativação é normalizado e redimensionado para uma dimensão espacial comum. Em seguida, para cada imagem no lote de dados, esses mapas de ativação processados e provenientes de diferentes camadas são agregados em uma única representação combinada. [9].

O núcleo da técnica reside na codificação agregada e aleatorizada. Essa representação agregada é processada por um conjunto de Autoencoders Aleatórios (RAE - Randomized Autoencoder). Cada RAE possui um codificador com pesos gerados aleatoriamente, através de um Gerador Linear Congruencial (LCG), e que não são treinados. O método então calcula os pesos do decodificador através de uma solução de mínimos quadrados, que condensa as características da ativação agregada. Os recursos resultantes de cada RAE são então somados para formar um único vetor de características final, que representa a textura da imagem de entrada de forma robusta. [9].

Para a classificação final, em vez de ajustar os pesos da CNN, o vetor de características gerado pelo RADAM é utilizado para treinar um classificador de Máquina de Vetores de Suporte (SVM) com um kernel linear, aproveitando a biblioteca scikit-learn. [9].

O SVM é um algoritmo de aprendizado de máquina supervisionado utilizado para classificação e regressão. Seu objetivo é identificar um hiperplano em um espaço dimensional que separa os pontos de dados de diferentes classes. O hiperplano selecionado como fronteira de decisão é aquele que maximiza a margem, definida como a distância entre ele e os pontos

de dados mais próximos de cada classe. Esses pontos mais próximos são denominados "vetores de suporte" e são os elementos que determinam a posição do hiperplano. Para dados não linearmente separáveis, o SVM pode utilizar funções de kernel para mapear os dados em espaços de dimensões superiores onde uma separação linear se torna possível [10].

A abordagem de feature extraction, em que a CNN pré-treinada é usada sem re-treinamento, requer menor custo computacional, como menos tempo de treinamento e menor uso de memória, comparado com o fine-tuning ou o treinamento completo da rede. [6].

A segunda abordagem se destaca por utilizar o BAMBOO um dos maiores repositórios de imagens já construídos para visão computacional, composto por mais de 69 milhões de anotações em mais de 119 mil categorias. Diferente de métodos que apenas extraem características de redes já treinadas, o BAMBOO explora o poder de arquiteturas de Redes Neurais Convolucionais (CNNs) modernas como a ResNet-50 que podem ser treinadas de ponta a ponta ou ajustadas a partir de pesos pré-treinados nesse gigantesco dataset. A principal inovação do BAMBOO está na sua escala massiva e na forma colaborativa com que foi desenvolvido, combinando curadoria humana e aprendizado de máquina contínuo, o que resulta em uma base de conhecimento visual extremamente abrangente e diversificada. [11].

Durante o processo de treinamento, a CNN aprende representações visuais robustas que englobam desde padrões de baixo nível, como cores, bordas e texturas, até conceitos mais abstratos e específicos de alto nível. Essa riqueza de representações confere ao modelo uma capacidade de generalização superior, permitindo sua aplicação em diferentes domínios de classificação de imagens, inclusive em contextos médicos desafiadores, como a detecção de células parasitadas por malária. [11].

Comparar as duas redes neurais — Bamboo-CLS (baseada em ResNet-50) e RADAM (com backbone ConvNeXt Nano) — é importante porque cada uma representa abordagens distintas de aprendizado e extração de características em imagens, o que impacta diretamente o desempenho, a robustez e a interpretabilidade dos resultados. O Bamboo-CLS realiza um treinamento supervisionado de ponta a ponta, ajustando todos os pesos da rede para otimizar a classificação das imagens [11]. Já o RADAM atua como um extrator de descritores de textura, capturando padrões mais finos e estruturais [9], que são então utilizados por um classificador tradicional (SVM) para fins deste estudo. Essa diferença metodológica permite avaliar como cada tipo de modelo lida com as variações visuais e o nível de detalhe presente nas imagens analisadas.

D. Protocolo Experimental

Pré-processamento e Divisão dos Dados:

O pré-processamento utilizado nos dois métodos apresentou diferenças importantes em relação à normalização e ao objetivo da preparação dos dados. No método Bamboo-CLS (ResNet-50), as imagens foram redimensionadas para 224×224 pixels, convertidas em tensores e normalizadas com média e desvio padrão iguais a 0.5, ajustando os valores de pixel para o intervalo [-1,1]. Esse tipo de normalização é genérica e visa padronizar as entradas para o treinamento supervisionado completo de uma rede neural profunda, permitindo que o modelo aprenda diretamente os padrões discriminativos das imagens.

Já no método RADAM + SVM, o pré-processamento também incluiu o redimensionamento e a conversão das imagens em tensores, porém com uma normalização baseada nos valores padrão do conjunto ImageNet (médias de 0.485, 0.456 e 0.406 e desvios padrão de 0.229, 0.224 e 0.225). Essa configuração é mais adequada para modelos pré-treinados, como o ConvNeXt Nano, utilizado como backbone para extração de descritores de textura com o RADAM. Nesse caso, o pré-processamento teve como finalidade preparar as imagens para a extração de características que posteriormente alimentaram um classificador SVM, e não o treinamento direto de uma rede neural convolucional.

Extração de Características/Treinamento:

Para o RADAM, as imagens de treinamento foram processadas pela rede pré-treinada para extrair os vetores de características. Um classificador SVM foi então treinado com esses vetores. Para o BAMBOO, o modelo foi treinado de ponta a ponta utilizando o conjunto de treinamento por N épocas com o otimizador Adam e a função de perda Cross-Entropy.

A configuração experimental foi planejada de forma a garantir uma comparação equilibrada entre os dois métodos avaliados. No caso do Bamboo-CLS (baseado na arquitetura ResNet-50), o modelo foi treinado de forma supervisionada em cinco épocas (epochs = 5), utilizando uma taxa de aprendizado (learning rate) de 1×10^{-4} e o otimizador Adam, amplamente empregado por sua capacidade de adaptação dinâmica da taxa de atualização dos pesos. O conjunto de dados foi dividido em 80% para treinamento e 20% para teste, com um tamanho de lote (batch size) igual a 16, e o embaralhamento das amostras foi realizado a cada época para melhorar a generalização. Essa configuração permitiu ao Bamboo-CLS ajustar seus pesos internamente, otimizando o reconhecimento das classes "saudável" e "parasitada" diretamente a partir das imagens.

Já o método RADAM + SVM utiliza uma abordagem diferente, voltada à extração de descritores de textura em vez do treinamento completo de uma rede neural. Nesse caso, foi empregado o ConvNeXt Nano como backbone pré-treinado




Fig. 4. Fluxograma do funcionamento do modelo RADAM junto com SVM

para a geração dos mapas de ativação, dos quais o RADAM extraiu vetores de características representando as texturas das imagens. Esses vetores foram então utilizados para treinar um classificador SVM com kernel linear. A divisão do conjunto de dados seguiu a mesma proporção — 80% para treino e 20% para teste — utilizando o método `train_test_split` com `random_state = 42` para garantir reprodutibilidade. Por não envolver um treinamento iterativo da rede, o RADAM não possui parâmetros como número de épocas ou taxa de aprendizado; o ajuste do modelo ocorreu apenas durante a fase de treinamento do SVM. Essa configuração permite avaliar a eficiência do RADAM na representação de texturas em comparação ao aprendizado direto do Bamboo-CLS. A Figura 4 mostra um fluxograma de como é o funcionamento do modelo RADAM junto com o SVM.

E. Métricas de Avaliação

Para comparar quantitativamente o desempenho dos modelos RADAM e BAMBOO, as seguintes métricas foram calculadas a partir dos resultados no conjunto de teste:

Acurácia: Mede a proporção de predições corretas em relação ao total de amostras.

Matriz de Confusão: Uma tabela que visualiza o desempenho do classificador, detalhando os acertos e erros para cada classe (Verdadeiros Positivos, Falsos Positivos, Verdadeiros Negativos e Falsos Negativos) [12].

Recall: A proporção de todos os positivos reais que foram classificados corretamente como positivos. [13]. Pode ser definido como:

$$\text{Recall} = \frac{\text{verdadeiros positivos}}{\text{verdadeiros positivos} + \text{falsos negativos}} \quad (1)$$

Precisão: É a proporção de todas as classificações positivas do modelo que são realmente positivas. [13]. Pode ser definida como:

$$\text{Precisão} = \frac{\text{verdadeiros positivos}}{\text{verdadeiros positivos} + \text{falsos positivos}} \quad (2)$$

III. RESULTADOS

A. Desempenho Geral de Classificação

Os modelos RADAM e BAMBOO foram avaliados no conjunto de teste para a tarefa de classificação de células de malária. O desempenho geral de cada modelo, medido em termos de acurácia, taxa de erro e precisão está resumido na Tabela I.

TABELA I
MÉTRICAS DE DESEMPENHO

Métricas	Modelo RADAM	Modelo BAMBOO
Acurácia	0.9609	0.9663
Recall	0.9684	0.9731
Precisão	0.9542	0.9590

Conforme apresentado na Tabela I, os resultados de desempenho dos modelos RADAM e BAMBOO a partir das métricas de acurácia, recall e precisão. Observa-se que o modelo BAMBOO obteve desempenho ligeiramente superior em todas as medidas analisadas. Em termos de acurácia, o RADAM atingiu 96,09%, enquanto o BAMBOO alcançou 96,63%, representando um ganho de 0,54 pontos percentuais. Já no recall, o RADAM registrou 96,84% e o BAMBOO 97,31%, evidenciando maior sensibilidade do segundo modelo para identificar corretamente os casos positivos e, consequentemente, reduzir a ocorrência de falsos negativos. A métrica de precisão também reforça a superioridade do BAMBOO, que obteve 95,90% frente aos 95,42% do RADAM, indicando menor taxa de falsos positivos nas classificações.

B. Análise Detalhada com a Matriz de Confusão

Para uma análise mais detalhada dos tipos de erros de classificação, as matrizes de confusão para ambos os modelos foram geradas. A Figura 5 apresenta a matriz de confusão para o modelo RADAM, e a Figura 6 para o modelo BAMBOO.

A análise da Figura 5 revela que o modelo RADAM classificou corretamente 2669 células infectadas (Verdadeiros Positivos) e 2628 células saudáveis (Verdadeiros Negativos). O modelo cometeu 128 erros do tipo Falso Negativo (classificando uma célula infectada como saudável) e 87 erros do tipo Falso Positivo.

De forma similar, a Figura 6 mostra que o modelo BAMBOO obteve 2644 Verdadeiros Positivos e 2682 Verdadeiros




Fig. 5. Matriz de confusão do modelo RADAM.




Fig. 6. Matriz de confusão do modelo BAMBOO.

Negativos. No entanto, apresentou um número menor de erros, com 113 Falsos Negativos e 73 Falsos Positivos.

IV. DISCUSSÃO

A. Interpretação dos Resultados de Desempenho

A análise comparativa entre os modelos RADAM e BAMBOO, a partir das métricas de desempenho e das matrizes de confusão, evidencia que ambos apresentam resultados bastante satisfatórios, com pequenas variações que podem ser determinantes em aplicações práticas. O RADAM apresentou uma acurácia elevada (96,09%), demonstrando que a estratégia de utilizar redes convolucionais pré-treinadas como extratoras de características, seguida da classificação com um SVM linear, é bastante eficaz para o problema de reconhecimento de texturas. Esse bom desempenho pode ser atribuído ao fato

de que os mapas de ativação de múltiplas camadas capturam representações discriminativas da textura celular, mesmo sem a necessidade de re-treinamento do modelo. No entanto, a análise da matriz de confusão revelou que o RADAM ainda apresenta uma quantidade significativa de erros do tipo Falsos Negativos (128 casos), o que é particularmente crítico em aplicações médicas, já que significa que células infectadas foram classificadas como saudáveis. Além disso, apresentou 87 falsos positivos, classificando incorretamente células saudáveis como infectadas, o que pode gerar diagnósticos equivocados.

Já o BAMBOO demonstrou superioridade em todos os aspectos avaliados. Sua acurácia foi ligeiramente maior (96,63%), indicando maior capacidade de acerto geral. No recall, também se destacou (97,31% frente a 96,84% do RADAM), revelando maior eficiência em identificar corretamente os casos positivos, o que é fundamental em contextos de diagnóstico. Em termos de precisão, o BAMBOO obteve 95,90%, superando o RADAM (95,42%), o que significa menor ocorrência de falsos positivos e maior confiabilidade na predição dos casos classificados como positivos. A análise da matriz de confusão mostra uma redução tanto nos Falsos Negativos (113) quanto nos Falsos Positivos (73), além de apresentar 2654 verdadeiros positivos e 2682 verdadeiros negativos. Essa melhoria pode ser atribuída ao uso de uma arquitetura CNN (ResNet-50) treinada sobre o dataset em larga escala do BAMBOO, que fornece ao modelo uma base de conhecimento visual extremamente abrangente, favorecendo sua capacidade de generalização.

De modo geral, a discussão dos resultados permite afirmar que o BAMBOO apresenta maior robustez e confiabilidade, sendo mais eficiente tanto na detecção de casos positivos quanto na minimização de diagnósticos incorretos. O RADAM, por outro lado, embora um pouco menos preciso, ainda se mostra altamente competitivo e pode ser uma alternativa viável em cenários onde a demanda computacional seja um fator determinante, visto que seu desempenho é bastante próximo ao do BAMBOO. Assim, a escolha entre os modelos depende do equilíbrio entre custo computacional e a necessidade de máxima confiabilidade diagnóstica, com o BAMBOO sendo mais indicado em aplicações críticas que exigem maior segurança na classificação.

B. Limitação do Estudo

A pesar dos resultados promissores, este estudo possui algumas limitações. Primeiramente, a comparação foi realizada com apenas dois modelos; outras arquiteturas poderiam apresentar desempenhos diferentes. Além disso, o dataset utilizado, embora seja um padrão na área, possui imagens obtidas sob condições controladas de laboratório, e o desempenho dos modelos pode variar em imagens de microscopia de campo com

maior ruído ou artefatos. Por fim, há limitações de hardware os modelos são dependentes da arquitetura CUDA.

C. Trabalhos Futuros

Exploração de outros datasets médicos: Avaliar os modelos em diferentes conjuntos de imagens biomédicas (ex.: radiografias, exames histopatológicos, imagens de retina). Isso poderia validar a robustez e a generalização dos métodos além do domínio da malária.

Análise em condições de dados desbalanceados: Testar os modelos em datasets com maior desequilíbrio entre classes (mais células saudáveis que infectadas, por exemplo), já que esse cenário é comum em aplicações médicas reais.

Aplicações em tempo real: Adaptar os modelos para sistemas de detecção automática em tempo real, por exemplo, em microscópios digitais ou aplicativos móveis de apoio ao diagnóstico em regiões de baixa infraestrutura.

V. CONCLUSÃO

As redes neurais artificiais têm se consolidado como uma ferramenta poderosa para a resolução de problemas complexos, especialmente em tarefas relacionadas à análise de texturas, classificação e detecção de padrões em imagens médicas [2]–[4]. A literatura demonstra que, devido à sua capacidade de aprender representações internas a partir dos dados, essas redes conseguem identificar padrões visuais que muitas vezes escapam até mesmo ao olhar humano especializado, tornando-se aliadas valiosas no apoio ao diagnóstico clínico [5]–[7], [9], [14].

No contexto experimental, a comparação entre os modelos RADAM e BAMBOO reforça a relevância dessa tecnologia. O RADAM, ao utilizar redes convolucionais pré-treinadas apenas como extratoras de características combinadas a um classificador SVM, alcançou resultados expressivos, com acurácia de 96,09%, precisão de 95,42% e recall de 96,84%, evidenciando sua eficiência mesmo sem a necessidade de re-treinamento. Por outro lado, o BAMBOO, apoiado em uma base de dados massiva e no treinamento completo de uma arquitetura CNN, obteve desempenho ligeiramente superior, com acurácia de 96,63%, precisão de 95,90% e recall de 97,31%, além de mostrar maior equilíbrio na redução de erros de classificação, especialmente os falsos negativos, que são críticos em cenários médicos.

Dessa forma, pode-se concluir que tanto o RADAM quanto o BAMBOO apresentam soluções eficazes para o reconhecimento de texturas em imagens de células de malária, cada um com vantagens específicas. O RADAM se mostra competitivo e eficiente em termos computacionais, sendo adequado para contextos com recursos limitados. Já o BAMBOO se destaca em cenários clínicos que demandam alta confiabilidade e

mínima taxa de erro, oferecendo maior robustez e capacidade de generalização. Assim, este estudo evidencia não apenas o potencial das redes neurais na análise de texturas médicas, mas também a necessidade de alinhar a escolha da abordagem ao contexto de aplicação, equilibrando custo computacional, precisão diagnóstica e confiabilidade nos resultados.

REFERÊNCIAS

- [1] S. Haykin, *Redes neurais: princípios e prática*. Bookman Editora, 2001.
- [2] M. Mirzaei, M. B. Jamshidi, and Y. Hojatpour, “Applications of artificial neural networks in information system of management accounting,” *International Journal of Mechatronics, Electrical and Computer Technology*, vol. 7, no. 25, pp. 3523–3530, 2017.
- [3] M. L. C. S. Domingues, “Mineração de dados utilizando aprendizado não-supervisionado: um estudo de caso para bancos de dados da saúde,” 2003.
- [4] A. Materka, M. Strzelecki *et al.*, “Texture analysis methods—a review,” *Technical university of lodz, institute of electronics, COST B11 report, Brussels*, vol. 10, no. 1.97, p. 4968, 1998.
- [5] I. F. VIEIRA, “Análise quantitativa de imagens médicas funcionais utilizando métodos de reconhecimento de padrões e inteligência artificial,” 2018.
- [6] A. Chorny, “Fine tuning vs feature extraction in transfer learning,” *Codefinity Blog*, Dec. 2023, blog post, 9 min read. [Online]. Available: <https://codefinity.com/blog/Fine-Tuning-vs-Feature-Extraction-in-Transfer-Learning>
- [7] L. F. d. S. Scabini and O. M. Bruno, “A desenvolvida na usp é a melhor do mundo para reconhecer texturas [depoimento a ivan conterno],” *Jornal da USP*, 2024.
- [8] I. Arunava, “Cell images for detecting malaria,” Kaggle, 2018, acessado em October 11, 2025. [Online]. Available: <https://www.kaggle.com/datasets/iarunava/cell-images-for-detecting-malaria>
- [9] L. Scabini, K. M. Zielinski, L. C. Ribas, W. N. Gonçalves, B. De Baets, and O. M. Bruno, “Radam: Texture recognition through randomized aggregated encoding of deep activation maps,” *Pattern Recognition*, vol. 143, p. 109802, 2023.
- [10] C. Cortes and V. Vapnik, “Support-vector networks,” *Machine learning*, vol. 20, no. 3, pp. 273–297, 1995.
- [11] Y. Zhang, Q. Sun, Y. Zhou, Z. He, Z. Yin, K. Wang, L. Sheng, Y. Qiao, J. Shao, and Z. Liu, “Bamboo: Building mega-scale vision dataset continually with human-machine synergy,” *International Journal of Computer Vision*, pp. 1–16, 2025.
- [12] P. C. T. Gomes. (2024, october) Matriz de confusão: Como utilizar para análise de modelos? Acesso em [inserir data de acesso]. [Online]. Available: <https://www.datageeks.com.br/matriz-de-confusao/>
- [13] Google, “Classification: Accuracy, precision, recall, and related metrics,” Google Developers, 2024, acessado em October 11, 2025. [Online]. Available: <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall>
- [14] W. N. Galvão, “Segmentação de vasos sanguíneos utilizando redes neurais convolucionais: visualização e análise de correlação dos mapas de ativação,” 2023.