

Predição automatizada de neoplasia cervical utilizando modelos de IA e redes neurais em análises de colposcopia e citologia em meio líquido

Micael Davi Lima de Oliveira; Universidade Federal do Amazonas; micael.oliveira@ufam.edu.br

Letícia Fernanda da Silva Martins; Universidade Federal do Amazonas;

Beatriz Souza de Oliveira; Universidade Federal do Amazonas;

Vitória Helena Oliveira Castro Silva; Universidade Federal do Amazonas;

Jhenyffer Gabrielly do Nascimento Assunção; Universidade Federal do Amazonas;

Jaqueline Marques da Silva; Universidade Federal do Amazonas;

Pritesh Jaychand Lalwani; ILMD-FIOCRUZ Amazônia/ICB, Universidade Federal do Amazonas;

Toni Ricardo Martins; Universidade Federal do Amazonas;

1. Introdução

O câncer de colo de útero é a quarta neoplasia mais comum entre as mulheres em todo o mundo, com uma incidência e mortalidade particularmente elevadas em países de baixa e média renda ¹. A detecção precoce, através de programas de rastreamento, é a estratégia mais eficaz para combater a doença. O fluxo de diagnóstico convencional envolve um teste de Papanicolaou, seguido por uma colposcopia para visualizar o colo do útero sob magnificação e, se uma lesão suspeita for encontrada, uma biópsia é realizada para análise histopatológica, que é considerada o padrão-ouro ².

Apesar de ser um método consagrado, este processo possui limitações. A interpretação tanto das imagens colposcópicas quanto das lâminas histopatológicas depende da experiência do médico patologista, podendo haver uma variabilidade entre os profissionais³. Além disso, em regiões com recursos limitados, como em áreas remotas da Amazônia, o acesso a serviços especializados pode ser um gargalo, atrasando diagnósticos cruciais. Neste contexto, a Inteligência Artificial, especificamente o *Deep Learning*, emerge como uma tecnologia promissora para a análise de imagens clínicas²⁻⁴. Modelos de Visão Computacional podem aprender a identificar padrões complexos e sutis em imagens, invisíveis ao olho humano, oferecendo um potencial imenso para automatizar e padronizar análises, servindo como uma ferramenta de triagem para os especialistas, o que irá acelerar enormemente o diagnóstico em regiões precárias e remotas como no estado do Amazonas.

O objetivo deste trabalho é desenvolver, treinar e validar um modelo de *Deep Learning* para classificar lesões cervicais (ex: normais, lesões de baixo grau, lesões de alto grau, carcinoma) utilizando uma abordagem que integra informações de imagens de colposcopia e citologia em meio líquido, tendo como produto final um *software* de computador e posteriormente um aplicativo para Android. Comparamos sistematicamente o desempenho de diferentes arquiteturas de redes neurais convolucionais (CNNs), na busca pelo modelo com maior precisão de acerto a partir de bancos de dados públicos de imagem^{3,6}.

2. Materiais e Métodos

A metodologia foi conduzida na linguagem de programação Python 3.12 utilizando a IDE (Integrated Development Environment) em Nuvem conhecida como Google Colab, com o auxílio de bibliotecas como TensorFlow, PyTorch, Keras, Scikit-learn, OpenCV e Pandas.

2.1. Aquisição e Preparação do Conjunto de Dados

O conjunto de dados de treinamento utilizado neste estudo foi composto por 469 imagens de colposcopia, divididas em 4 (quatro) classes: I. Normal; II. LSIL; III. HSIL; IV. Carcinoma cervical, sendo respectivamente 213 imagens normais, 54 imagens LSIL, 157 imagens HSIL e 45 imagens de carcinoma cervical. Além disso, para validação do algoritmo utilizou-se outras imagens às quais o algoritmo não foi exposto anteriormente, correspondendo a 20% do total, o equivalente a 130 imagens divididas nas mesmas classes anteriores com 55 imagens normais, 17 imagens LSIL, 45 imagens HSIL e 13 imagens de carcinoma cervical. As imagens de colposcopia foram obtidas num dataset público ⁶, IARC Image Bank Colpo, pertencente ao projeto IARC (International Agency for Research on Cancer) da OMS (Organização Mundial de Saúde) disponibilizado em: <https://screening.iarc.fr/cervicalimagebank.php>

As imagens foram pré-processadas para garantir a consistência e otimizar o treinamento enfatizando o diagnóstico de imagens de câncer cervical. Esta etapa incluiu: Redimensionamento: Todas as imagens foram padronizadas para uma dimensão de 224 x 224 pixels; Ajuste de coloração: O parâmetro “color jitter” foi ajustado para $p=0.3$; Normalização das imagens: Utilizou-se o padrão de ImageNET com média de (0.485, 0.456, 0.406) e desvio-padrão de (0.229, 0.224, 0.225); Aumento de Dados (Data Augmentation): Para evitar sobreajuste (overfitting) e aumentar a variabilidade do dataset, foram aplicadas transformações aleatórias em tempo real durante o treinamento, como rotações, zooms, espelhamentos horizontais e pequenas alterações de brilho. Em resumo, o conjunto de dados foi dividido em três subconjuntos: 70% para treinamento, 15% para validação e 15% para teste, de um total de 599 imagens.

Um algoritmo semelhante também foi implementado usando imagens de citologia em meio líquido, com um número total de 769 imagens para treinamento e 194 para validação do algoritmo proveniente de lâminas coradas com hematoxilina e Eosina (H&E). O dataset utilizado encontra-se publicado com o título Liquid based cytology pap smear images for multi-class diagnosis of cervical cancer ³, em: <https://data.mendeley.com/datasets/zddtpgzv63/2>

2.2. Arquiteturas de Redes Neurais Avaliadas

Para identificar o modelo mais eficaz, foram implementadas e comparadas as seguintes arquiteturas de CNNs, pré-treinadas na base de dados ImageNet (Transfer Learning): ResNet50: Introduz as conexões residuais (“skip connections”) para permitir o treinamento de redes muito mais profundas, mitigando o problema do gradiente descendente; EfficientNetB3: uma família de modelos de última geração que utiliza um método de escalonamento composto, ajustando uniformemente a profundidade, largura e resolução da rede de forma otimizada para obter alta acurácia com menor custo computacional ⁵; MobileNET: um modelo de menor complexidade computacional mas ideal para portabilidade em celulares, possibilitando a predição mesmo em lugares remotos e sem acesso à internet.

2.3. Treinamento e Métricas de Avaliação

Os modelos foram treinados por um número de 50 épocas (epochs), isto é, passagens de treinamento que o algoritmo é exposto às mesmas imagens do dataset, utilizando o otimizador Adam com uma taxa de aprendizado de 10^{-4} e a função de perda categórica *crossentropy*. O treinamento foi realizado em uma máquina equipada com uma GPU NVIDIA Tesla T4 Turing de 16 GB integrada à plataforma em nuvem do Google Colab. O desempenho foi avaliado utilizando as seguintes métricas, calculadas sobre o conjunto de teste:

$$\begin{aligned}
\text{Precisão} &= \frac{\sum VP}{\sum VP + FP} \\
\text{Acurácia} &= \frac{\sum VP + VN}{\sum VP + FP + FN + VN} \\
\text{Recall} &= \frac{\sum VP}{\sum VP + FN} \\
F1_{Score} &= 2 * \frac{\text{Precisão} * \text{Recall}}{\text{Precisão} + \text{Recall}}
\end{aligned}$$

Verdadeiro Positivo (VP)

Falso Negativo (FN)

Falso Positivo (FP)

Verdadeiro Negativo (VN)

Figura 1. Métricas de avaliação da capacidade do algoritmo prever corretamente as imagens de colposcopia e citologia líquida.

3. Resultados e Discussão

Os modelos foram avaliados num conjunto de imagens de teste separado, que não foi utilizado durante o treinamento ou validação, o que minimiza o viés de análise. Conforme os dados apresentados, o EfficientNetB3 demonstrou uma superioridade consistente em todas as métricas avaliadas. O modelo alcançou a maior acurácia, indicando uma performance de classificação mais robusta e confiável com precisão de 93%. A análise das matrizes de confusão também revelou que a EfficientNetB3 teve uma taxa menor de falsos negativos para as classes de lesões de alto grau, um aspecto clinicamente muito relevante (Figuras 2 e 3).

Os resultados confirmam o potencial da abordagem de Deep Learning para a predição de câncer de colo de útero principalmente em citologia líquida, embora em colposcopia as taxas de acerto estejam acima de 90%, o índice de erro é maior. A superioridade da EfficientNet pode ser atribuída à sua inovadora estratégia de escalonamento. Enquanto arquiteturas como a ResNet focam primariamente em aumentar a profundidade da rede, a EfficientNet otimiza simultaneamente profundidade, largura e resolução de imagem, encontrando um balanço que maximiza a extração de características relevantes sem um aumento no número de parâmetros. Isso a torna não apenas mais precisa, mas também computacionalmente mais eficiente, o que é vital para uma futura implementação clínica em tempo real especialmente em lugares remotos. A utilização de uma abordagem que permita a leitura de imagens de colposcopia (visão macroscópica) e citologia líquida (visão microscópica), possibilita um diagnóstico mais preciso, embora os algoritmos trabalhem separadamente (Figuras 2 e 3).

Resultado da predição: Lesão intraepitelial escamosa alta (HSIL) (100.00%)




Figura 2. Resultado de uma das predições para citologia em meio líquido, classificando de forma correta uma lesão do tipo HSIL com probabilidade de 100%.

Resultado da predição: Carcinoma (96.81%)




Figura 3. Predição de carcinoma cervical com 96,81% de probabilidade de acerto, o que foi confirmado no dataset disponibilizado.

Este sistema, se validado em estudos prospectivos, poderia funcionar como uma ferramenta poderosa de apoio ao diagnóstico. Para o colposcopista, poderia destacar áreas de maior risco em tempo real. Para o patologista, poderia pré-analisar lâminas, priorizando os casos mais suspeitos e reduzindo o tempo de análise. Em locais com carência de especialistas, como em muitas cidades do interior do Brasil, especialmente em municípios do Amazonas, um sistema como este poderia realizar uma triagem inicial de alta qualidade, permitindo que apenas os casos mais complexos sejam enviados para centros de referência.

As limitações deste estudo incluem o tamanho do dataset e a necessidade de validação com diferentes populações e equipamentos, futuramente num contexto clínico, como por exemplo com pacientes da FCecon (Fundação Centro de Controle de Oncologia do Estado do Amazonas).

5. Conclusões

Este trabalho demonstra de maneira promissora o desenvolvimento e consequente validação de um sistema de IA para a predição de câncer de colo de útero a partir de imagens de colposcopia e citologia em meio líquido com precisão de 93%, considerando as imagens treinadas. A comparação rigorosa entre diferentes arquiteturas de CNNs, implementadas em Python, revelou que a EfficientNet é a mais adequada para esta tarefa complexa, oferecendo a melhor performance em acurácia e precisão. Os resultados são promissores e abrem caminho para futuras pesquisas, incluindo a integração do modelo em *softwares* de visualização de imagens em serviços especializados, além de um aplicativo para Android e a condução de ensaios clínicos para avaliar seu impacto em um cenário de vida real. Por fim, a IA se apresenta não como um substituto, mas como um poderoso aliado para os profissionais de saúde na luta contra o câncer de colo do útero em regiões de difícil acesso.

Agradecimentos

Ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) pela bolsa de iniciação científica ofertada pela Fiocruz - ILMD (Instituto Leônicas & Maria Deane).

Divulgação

O (s) autor (es) e revisores não relataram qualquer conflito de interesse durante a sua avaliação. Logo, o Congresso Pan-Amazônico de Oncologia detém os direitos autorais, tem a aprovação e a permissão dos autores para divulgação deste resumo, por meio eletrônico.

Referências

- [1] Sung, H., Ferlay, J., Siegel, R. L., et al. (2021). Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA: A Cancer Journal for Clinicians*, 71(3), 209-249.
- [2] BenO, Jones, Kumar H, Meg Risdal, MRao, Vadim Sherman, Vipul, Wendy Kan, and Yau Ben-Or. Intel & MobileODT Cervical Cancer Screening. <https://kaggle.com/competitions/intel-mobileodt-cervical-cancer-screening>, 2017. Kaggle.
- [3] Hussain E, Mahanta LB, Borah H, Das CR. Liquid based-cytology Pap smear dataset for automated multi-class diagnosis of pre-cancerous and cervical cancer lesions. Data in Brief [Internet]. 2020 jun;30:105589. Available from: <http://dx.doi.org/10.1016/j.dib.2020.105589>
- [4] Wang J, Yu Y, Tan Y, Wan H, Zheng N, He Z, et al. Artificial intelligence enables precision diagnosis of cervical cytology grades and cervical cancer. Nat Commun [Internet]. 2024 maio 22;15(1). Available from: <http://dx.doi.org/10.1038/s41467-024-48705-3>
- [5] Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the 36th International Conference on Machine Learning*, 6105-6114.
- [6] International Agency for Research on Cancer. IARC Cervical Cancer Image Bank [Internet]. Lyon: IARC; 2021 [citado em 31 ago 2025]. Disponível em: <https://screening.iarc.fr/cervicalimagebank.php>