

OvaHybrid: Representação por Fusão de Canais e Classificação Explicável de Subtipos de Câncer de Ovário em Imagens Histopatológicas

Raphael S. R. Rates¹, Luana B. da Cruz¹, João O. B. Diniz²

¹Laboratório de Inteligência Computacional Aplicada (LICA)
Universidade Federal do Cariri (UFCA)

²Fábrica de Inovação
Instituto Federal do Maranhão (IFMA)

raphael.rates@aluno.ufca.edu.br, luana.batista@ufca.edu.br

joao.bandeira@ifma.edu.br

Abstract. *Ovarian cancer is characterized by high mortality and heterogeneity of histological subtypes, which challenges early diagnosis. This work presents OvaHybrid, a hybrid approach that integrates image processing and Deep Feature extraction to classify ovarian cancer subtypes in histopathological images. The method uses channel fusion combined with Deep Features to enrich the representation of features. Hyperparameter optimization was performed using the Optuna framework. The best configuration (ResNet50 + SVM) achieved an accuracy of 97.96%, precision of 98.13%, sensitivity of 97.96%, specificity of 98.95% and an F1-score of 97.95%, indicating high effectiveness in diagnosis.*

Resumo. *O câncer de ovário é caracterizado por alta mortalidade e heterogeneidade de subtipos histológicos, o que desafia o diagnóstico precoce. Este trabalho apresenta o OvaHybrid, uma abordagem híbrida que integra processamento de imagens e extração de Deep Features para classificar subtipos de câncer de ovário em imagens histopatológicas. O método utiliza fusão de canais combinada a Deep Features para enriquecer a representação das características. A otimização de hiperparâmetros foi realizada utilizando o framework Optuna. A melhor configuração (ResNet50 + SVM) obteve acurácia de 97,96%, precisão de 98,13%, sensibilidade de 97,96%, especificidade de 98,95% e F1-score de 97,95%, indicando alta eficácia no diagnóstico.*

1. Introdução

O câncer constitui uma das doenças de maior impacto na mortalidade global, definido por alterações celulares que promovem crescimento e proliferação desregulados, frequentemente associados a fatores genéticos e ambientais, resultando na formação de massas tumorais [Peneira et al. 2025]. Atualmente, diversos tipos de câncer são reconhecidos, entre os quais o câncer de ovário se destaca pela sua relevância clínica. Seus múltiplos subtipos apresentam características biológicas distintas, o que representa um desafio significativo para o diagnóstico e o tratamento, tornando-o um tema de grande preocupação na área médica [Sung et al. 2021].

O câncer de ovário está entre as neoplasias mais letais que afetam as mulheres, sendo a oitava principal causa de morte por câncer no mundo [World Ovarian Cancer Coalition 2022]. Em 2022, foram registrados mais de 300.000 novos casos no mundo, o que destaca sua relevância epidemiológica. No Brasil, estima-se que ocorrerão aproximadamente 8.020 novos casos em 2026 [Instituto Nacional de Câncer (INCA) 2026]. Esse quantitativo corresponde a cerca de 3,1% de todas as neoplasias que ocorrem na população feminina o câncer de ovário representa uma parcela significativa da carga oncológica nacional.

Com os avanços tecnológicos na área médica, a análise de amostras de tecido em nível celular tem se tornado cada vez mais relevante para fins diagnósticos. Esse processo integra os exames de imagens histopatológicas, contribuindo de forma significativa para a identificação e a classificação de alterações patológicas [Beaufort et al. 2014]. No entanto, esse procedimento está suscetível à variabilidade entre observadores, comprometendo a padronização e a consistência diagnóstica. Diante disso, ferramentas baseadas em Inteligência Artificial (IA) estão sendo exploradas como alternativas para enfrentar esse desafio, incluindo abordagens de aprendizado de máquina e aprendizado profundo, que têm demonstrado potencial para impulsionar avanços na análise de imagens em patologia [Alvino et al. 2025, Tamanini et al. 2025].

Este trabalho propõe o OvaHybrid, uma abordagem para classificação de subtipos de câncer de ovário em imagens histopatológicas, com as seguintes contribuições: (1) combina Redes Neurais Convolucionais (CNNs) como extratores de *Deep Features* com classificadores clássicos, explorando uma estratégia híbrida; (2) incorpora técnicas de processamento de imagem, como fusão de canais de cor, para aprimorar a representação das imagens e a extração de *Deep Features* relevantes; e (3) realiza uma análise comparativa entre diferentes arquiteturas e classificadores, com otimização de hiperparâmetros e interpretação do método por meio de explicações visuais que destacam as regiões mais relevantes para a classificação e aumentam a transparência das decisões. Essas estratégias resultam em uma abordagem eficaz para auxiliar no diagnóstico do câncer de ovário.

2. Trabalhos Relacionados

A literatura apresenta diversos estudos que exploram técnicas de aprendizado de máquina, aprendizagem profunda e engenharia de características para a classificação de câncer de ovário em imagens histopatológicas. Esses trabalhos são discutidos nesta seção.

No estudo [Bikku et al. 2025], foi proposto um modelo de classificação binária entre as classes de ovário não cancerígeno e ovário cancerígeno, considerando como classe cancerígena a junção dos subtipos endometriode, células claras, mucinoso e seroso [Mallya et al. 2025], cuja configuração combina o pré-processamento com filtro de *Wiener* e *Contrast Limited Adaptive Histogram Equalization* (CLAHE) com a CNN DenseNet121. Os autores alcançaram 95,30% de acurácia e 95,00% de sensibilidade. O estudo [Alvino et al. 2025] apresenta um método para classificação binária entre câncer de ovário endometriode e ovário saudável. Foram avaliados múltiplos esquemas de cor e classificadores, sendo a melhor configuração a combinação da VGG16 como extratora de características, o classificador *Support Vector Machine* (SVM), com pré-processamento em escala de cinza, alcançando 94,99% de acurácia e 95,15% de sensibilidade.

O trabalho [Rahman et al. 2025] apresenta uma classificação multiclasse em ima-

gens histopatológicas usando *transfer learning* com DenseNet201 e interpretação via *Interpretable Model-agnostic Explanations* (LIME), mostrando resultados de 95,64% de acurácia e 95,60% de sensibilidade. Em [Tamanini et al. 2025], foi proposto um método para classificação binária entre ovário saudável e câncer de ovário seroso. O método combinou transformação de cores YCrCb, extração de características *Radiomics*, seleção de *Deep Features* via *Recursive Feature Elimination* (RFE) e classificação com *Random Forest* (RF). Essa estratégia obteve 97,96% de acurácia e 99,98% de sensibilidade, evidenciando o impacto da engenharia de características no desempenho do método.

Em [Alahmadi 2024], investigaram arquiteturas baseadas em *Vision Transformers* combinadas com o LIME para classificação multiclasse entre subtipos de câncer de ovário. A melhor configuração, baseada no ViT-Large-P32-384, atingiu 98,79% de acurácia e 97,37% de sensibilidade. [El-Latif et al. 2024] apresentaram um modelo híbrido integrando ResNet50, seleção de características por RFE e lógica *fuzzy* para a classificação binária entre células saudáveis e cancerígenas em 288 lâminas histopatológicas. O método alcançou 98,99% de acurácia e 98,96% de sensibilidade.

Embora diversos trabalhos apresentem bons resultados na classificação de câncer de ovário, alguns deles se limitam à classificação binária [Bikku et al. 2025, Alvino et al. 2025, Tamanini et al. 2025, El-Latif et al. 2024], o que simplifica o problema e não contempla a distinção entre múltiplos subtipos histológicos. Além disso, outro estudo [Rahman et al. 2025] considera apenas amostras patológicas, desconsiderando tecidos saudáveis, o que torna o cenário menos representativo da prática clínica. A inclusão de amostras é fundamental em aplicações de triagem, pois permite diferenciar casos normais daqueles que requerem maior atenção clínica. Diante disso, evidencia-se a necessidade de métodos mais robustos, capazes de realizar classificação multiclasse abrangendo tanto tecidos saudáveis quanto diferentes subtipos da doença.

Além disso, a literatura explora diferentes estratégias para aprimorar a classificação, como arquiteturas profundas para extração de características, modelos híbridos e técnicas de interpretabilidade para análise das decisões dos modelos. No entanto, essas abordagens são frequentemente empregadas de forma isolada, o que dificulta analisar seu impacto combinado. Nesse contexto, este trabalho propõe uma abordagem que integra essas estratégias e incorpora a fusão de canais de cor para enriquecer a representação das imagens e favorecer a extração de características mais discriminativas para a classificação de subtipos de câncer de ovário.

3. Materiais e Método Proposto

Esta seção apresenta os materiais e o método proposto. Inicialmente é descrito a base de imagens utilizada para validar o método. Em seguida, são detalhadas as etapas de pré-processamento, incluindo a aplicação de *data augmentation* e a fusão de canais de cor, com o objetivo de aprimorar a extração de características. Posteriormente, as *Deep Features* são extraídas por meio de CNNs e utilizadas por classificadores clássicos, cujos hiperparâmetros são otimizados via *Tree-structured Parzen Estimator* (TPE). Finalmente, métricas de avaliação são utilizadas para analisar o desempenho do método. As etapas podem ser visualizadas na Figura 1.

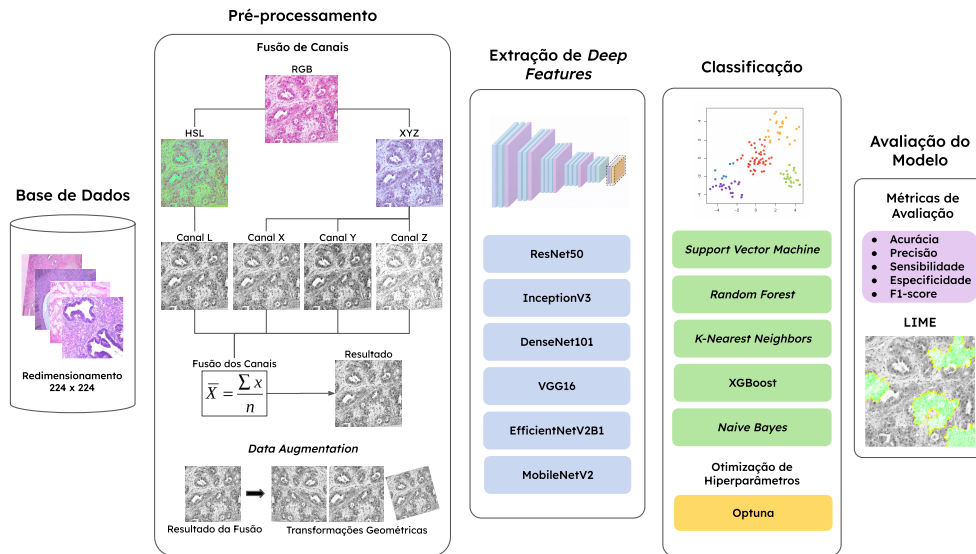


Figura 1. Etapas do método proposto para classificar subtipos de câncer de ovário.

3.1. Base de Dados

A base de dados utilizada neste estudo, denominada *Ovarian Cancer & Subtypes Dataset Histopathology* [Kasture 2021], consiste em 498 imagens distribuídas em cinco classes categorizadas. Dentre essas classes, quatro correspondem a subtipos de carcinoma de ovário (células claras, endometriode, mucinoso e seroso de alto grau), enquanto a quinta representa uma classe não cancerígena.

A resolução das imagens variavam entre 225 e 888 *pixels* de altura e 225 a 550 *pixels* de largura, no qual as imagens foram redimensionadas para 224×224 *pixels*, a fim de compatibilizá-las com as dimensões de entrada padrão das arquiteturas de CNN pré-treinadas na ImageNet, assegurando a padronização das amostras e maior consistência nas etapas subsequentes do processamento [El-Latif et al. 2024]. Cada classe possui 100 imagens, com exceção da carcinoma de ovário endometriode, que apresenta 98 imagens. Essa distribuição reflete a composição original da base de dados. Para os experimentos neste estudo, a base de dados foi dividida em um *hold-out* de 80% para treinamento e 20% para teste. Para validar e definir os melhores hiperparâmetros foi utilizado metade dos dados do subconjunto de teste.

3.2. Pré-processamento

Na etapa de pré-processamento, duas cópias foram geradas em diferentes espaços de cor: o modelo XYZ e HSL [Gonzalez and Woods 2010], permitindo explorar distintas representações de cor e intensidade presentes na imagem original. Posteriormente, do modelo HSL foi extraído o canal L, responsável por concentrar as informações relacionadas ao brilho. Do modelo XYZ, foram extraídos os canais X, Y e Z, associados, respectivamente, as variações de tons avermelhados na percepção humana, à luminância perceptual real da imagem e as regiões com predominância de tons azulados. A partir dos canais extraídos, foi realizada uma fusão utilizando a média aritmética dos *pixels*, resultando em uma imagem em escala de cinza que combina informações estruturais e de

luminância, tornando a representação mais robusta para as etapas seguintes.

Em seguida, a técnica de *data augmentation* foi aplicada para ampliar a variabilidade do conjunto de treinamento e mitigar o sobreajuste (*overfitting*). Essa estratégia consiste em gerar variações das imagens dinamicamente por meio de transformações geométricas aleatórias, preservando suas *Deep Features* relevantes. O *data augmentation* foi implementado diretamente como uma camada sequencial das CNNs, incluindo rotação aleatória de até 5%, zoom de até 5% e espelhamento horizontal. Essa abordagem aumenta a diversidade dos dados e contribui para maior robustez do modelo e melhor desempenho dos classificadores. A Figura 2 ilustra as etapas do pré-processamento.

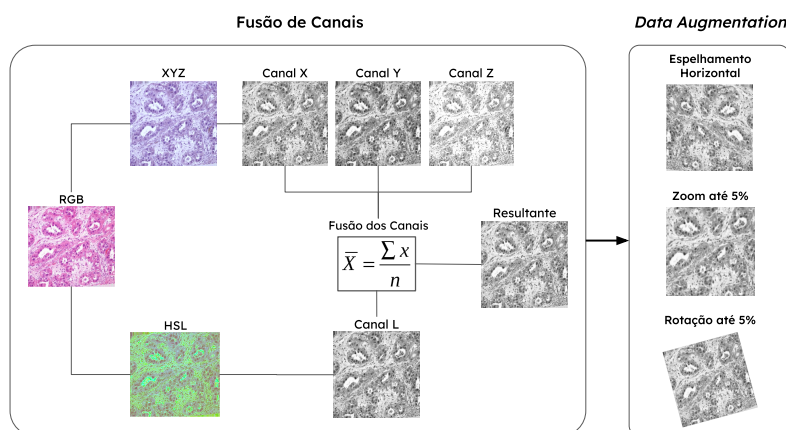


Figura 2. Etapas do pré-processamento.

3.3. Extração de *Deep Features*

Nesta etapa, seis arquiteturas de CNN pré-treinadas amplamente reconhecidas foram utilizadas para extrair *Deep Features* das imagens resultantes do pré-processamento. As arquiteturas definidas representam diferentes estratégias estruturais, incluindo conexões residuais (ResNet50), conexões densas (DenseNet121), módulos multiescala (InceptionV3), modelos leves e eficientes (MobileNetV2), arquiteturas sequenciais tradicionais (VGG16) e abordagens baseadas em escalonamento composto (EfficientNetV2B1) [Saha et al. 2025]. Esses modelos foram empregados como extratores de *Deep Features* para avaliar sua capacidade de gerar representações discriminativas considerando a fusão de canais de cor e sua generalização em diferentes cenários de classificação.

3.4. Classificação

Na etapa de classificação, foram empregados algoritmos clássicos amplamente utilizados na literatura para categorizar as imagens a partir das *Deep Features* previamente extraídas [Pavel et al. 2025]. Foram avaliados classificadores baseados em diferentes estratégias de aprendizado supervisionado, incluindo o SVM, que busca um hiperplano de margem máxima para separar as classes; o *K-Nearest Neighbors* (KNN), baseado nos vizinhos mais próximos; o *Naive Bayes* (NB), um modelo probabilístico fundamentado no Teorema de Bayes; o RF, um método de *ensemble* de árvores de decisão; e o XGBoost, uma variante otimizada de *gradient boosting* que utiliza regularização e *ensemble* de árvores para melhorar o desempenho e a generalização.

3.4.1. Otimização de Hiperparâmetros dos Classificadores

A otimização de hiperparâmetros busca identificar a melhor combinação de configurações que maximize o desempenho do modelo. Diferentemente dos parâmetros aprendidos no treinamento, os hiperparâmetros são definidos previamente e influenciam o comportamento e a capacidade de generalização dos algoritmos.

Neste estudo, esse processo foi aplicado nos classificadores utilizados (subseção 3.4). A otimização foi realizada com o framework Optuna, por meio do algoritmo TPE, uma abordagem de otimização Bayesiana. Diferentemente de métodos tradicionais, como *Grid Search* ou *Random Search*, o TPE modela probabilisticamente o desempenho dos hiperparâmetros, aprendendo com base nos resultados anteriores. Essa estratégia reduz avaliações desnecessárias, aumenta a eficiência da otimização e contribui para maior robustez e melhor desempenho final do método, especialmente em arquiteturas profundas com múltiplos hiperparâmetros contínuos e discretos [Rawi et al. 2023].

3.5. Avaliação do Modelo

Para avaliar o desempenho do método proposto, foram empregadas tanto técnicas de avaliação quantitativa quanto uma abordagem de interpretabilidade do método, no qual foi possível compreender os fatores que influenciaram as decisões dos modelos.

3.5.1. Métricas de Avaliação

Para avaliação quantitativa, foram utilizadas as métricas acurácia (ACC), sensibilidade (*recall*) (SEN), precisão (PRE), especificidade (ESP) e F1-score [El-Latif et al. 2024], que permitem avaliar o desempenho considerando tanto o acerto global quanto o equilíbrio entre falsos positivos e falsos negativos.

3.5.2. Explicabilidade

Além da avaliação quantitativa, foi empregada a técnica LIME para analisar as decisões do modelo por meio da classe LimeImageExplainer, disponibilizada na biblioteca LIME para interpretação de modelos aplicados a imagens.

O LIME é uma técnica de interpretabilidade independente do modelo que explica predições individuais por meio da aproximação local do comportamento do classificador. Para isso, a imagem é segmentada em *superpixels*, que são perturbados pela ativação ou desativação dessas regiões para observar como as predições do modelo variam e estimar a contribuição de cada região para a decisão final [Ribeiro et al. 2016]. Esse processo gera explicações visuais que evidenciam as regiões mais influentes na decisão do classificador, em que áreas em verde indicam aumento na probabilidade da classe predita e áreas em vermelho indicam diminuição dessa probabilidade. Em imagens histopatológicas, essas visualizações auxiliam na identificação de padrões morfológicos relevantes, aumentando a transparência e a interpretabilidade do método e permitindo que especialistas compreendam e validem as decisões do modelo como apoio ao diagnóstico clínico.

4. Resultados

Esta seção apresenta o ambiente experimental, a validação das etapas do método, estudos de caso e a comparação com trabalhos relacionados.

4.1. Ambiente Experimental

Os experimentos foram conduzidos no ambiente do Google Colab, com GPU NVIDIA T4, aproximadamente 12,7 GB de memória RAM e 15 GB de memória de vídeo (VRAM). A implementação foi realizada em Python versão 3, com o suporte das bibliotecas Pandas, OpenCV, Scikit-learn, TensorFlow, Keras, XGBoost e Optuna.

4.2. Resultados dos Modelos de Cores

Com o objetivo de identificar o modelo de cores mais adequado e avaliar o impacto da fusão de canais, foram considerados os espaços de cores RGB, XYZ e HSL, bem como a abordagem baseada na fusão de canais extraídos desses modelos. Para a avaliação foi utilizada a arquitetura ResNet50 para extração de *deep features*, combinada com o classificador *Random Forest* (RF) com otimização de hiperparâmetros via TPE. O *data augmentation* foi aplicado em todos os experimentos realizados e adotado de forma consistente nas análises subsequentes. Os resultados obtidos são apresentados na Tabela 1.

Tabela 1. Comparação de desempenho em diferentes espaços de cor e na fusão de canais.

Modelo de Cor	ACC	PRE	SEN	ESP	F1-score
RGB (original)	86,27%	89,29%	86,27%	88,65%	86,48%
XYZ	92,16%	93,33%	92,16%	93,13%	92,35%
HSL	88,24%	90,53%	88,24%	90,34%	88,57%
Fusão de Canais	94,12%	94,44%	94,12%	95,43%	94,19%

Conforme mostrado na Tabela 1, os resultados destacam a relevância da representação de cores no método proposto, uma vez que os modelos de cor alternativos (XYZ e HSL) apresentaram desempenho superior em relação ao RGB original. O espaço XYZ apresentou um ganho de aproximadamente 6% na acurácia e no F1-score, enquanto o HSL também superou o RGB, porém com ganhos menores nessas métricas.

A fusão de canais, por sua vez, apresentou o melhor desempenho geral, alcançando 94,12% de acurácia e 94,19% de F1-score. Em comparação ao RGB original, há um ganho de aproximadamente 8% nessas métricas, evidenciando que a combinação das diferentes representações de cor favorece a extração de características mais discriminativas e melhora o equilíbrio da classificação entre as classes.

4.3. Resultados das CNNs como extratoras de *Deep Features*

Com a fusão de canais definida como representação de entrada, a etapa seguinte consiste em identificar a arquitetura de CNN mais eficaz na extração de *Deep Features*. O classificador RF foi utilizado para avaliar o desempenho das *Deep Features* extraídas. A Tabela 2 apresenta os resultados obtidos nessa comparação.

Pode-se observar que a arquitetura ResNet50 apresentou o melhor desempenho na extração de *Deep Features*, alcançando 94,12% de acurácia e 94,19% de F1-score, indicando bom desempenho geral e equilíbrio entre as métricas de precisão e sensibilidade.

Tabela 2. Comparação de desempenho de diferentes CNNs na extração de *Deep Features* com fusão de canais.

Modelo	ACC	PRE	SEN	ESP	F1-score
ResNet50	94,12%	94,44%	94,12%	95,43%	94,19%
MobileNetV2	92,16%	92,31%	92,16%	90,20%	92,06%
InceptionV3	90,20%	90,23%	90,20%	91,50%	89,99%
DenseNet121	86,27%	88,21%	86,27%	87,40%	86,58%
EfficientNetV2B1	92,16%	92,94%	92,16%	92,87%	92,34%
VGG16	86,27%	87,91%	86,27%	88,36%	86,65%

Observa-se que seu desempenho supera as demais arquiteturas avaliadas, incluindo modelos mais leves, como MobileNetV2, e arquiteturas mais profundas, como DenseNet121, evidenciando sua elevada capacidade de representação.

Esse desempenho pode estar associado à sua estrutura baseada em conexões residuais, que facilitam o fluxo de gradientes durante o treinamento e permitem o aprendizado de representações mais profundas e discriminativas. Essa característica é particularmente relevante no contexto de imagens histopatológicas com fusão de canais, nas quais padrões sutis de textura e variações estruturais são combinados. Dessa forma, a ResNet50 demonstra maior capacidade de capturar essas informações de forma eficiente, contribuindo para a distinção entre os subtipos analisados [Soslow 2008].

4.4. Resultados dos Classificadores

Após definir a fusão de canais e a ResNet50 como extratora de *Deep Features*, foi realizada a comparação entre diferentes classificadores. As características extraídas foram utilizadas como entrada para os classificadores avaliados, no qual foram otimizados usando o framework Optuna. Os resultados são apresentados na Tabela 3.

Tabela 3. Comparação de desempenho dos classificadores com fusão de canais e ResNet50.

Classificador	ACC	PRE	SEN	ESP	F1-score
SVM	97,96%	98,13%	97,96%	98,95%	97,95%
KNN	80,39%	80,97%	81,93%	80,10%	80,39%
NB	70,59%	71,44%	75,76%	73,25%	70,59%
RF	94,12%	94,44%	94,12%	95,43%	94,19%
XGBoost	93,87%	94,23%	93,87%	92,50%	93,85%

O classificador SVM apresentou o melhor desempenho entre os métodos avaliados, alcançando 97,96% de acurácia, 98,13% de precisão, 97,96% de sensibilidade, 98,95% de especificidade e 97,95% de F1-score, mostrando um bom equilíbrio entre detecção correta e baixa taxa de erro. Observa-se que os classificadores baseados em *ensemble*, como RF e XGBoost, também apresentaram desempenho competitivo, com valores próximos a 94% nas métricas. Por outro lado, métodos baseados em instância e probabilísticos, como KNN e NB, apresentaram desempenho significativamente inferior, evidenciando menor capacidade de adaptação ao espaço de características extraído.

O desempenho superior do SVM pode estar relacionado à sua capacidade de encontrar hiperplanos de separação em espaços de alta dimensão, uma característica particularmente adequada para as *Deep Features* extraídas pela ResNet50. Essas representações tendem a ser mais discriminativas, favorecendo classificadores que exploram margens de separação bem definidas entre classes.

4.5. Comparação com e sem o uso do Optuna

Para avaliar o impacto da otimização de hiperparâmetros no método proposto, foi realizada uma comparação entre a configuração padrão do classificador SVM e a configuração otimizada com o framework Optuna. Os resultados obtidos podem ser vistos na Tabela 4.

Tabela 4. Comparação com e sem o uso do Optuna.

Configuração	ACC	PRE	SEN	ESP	F1-score
Padrão	94,12%	94,68%	94,12%	94,13%	94,14%
Optuna	97,96%	98,13%	97,96%	98,95%	97,95%

Conforme apresentado na Tabela 4, a utilização do Optuna resultou em melhorias consistentes em todas as métricas avaliadas. Observa-se um aumento de aproximadamente 3,8% na acurácia, além de ganhos semelhantes nas demais métricas. Esses resultados indicam que a otimização de hiperparâmetros usando Optuna contribuiu significativamente para o aprimoramento do desempenho do modelo, ao explorar o espaço de hiperparâmetros de forma probabilística e priorizar regiões mais promissoras, permitindo encontrar configurações mais adequadas para o classificador SVM.

4.6. Estudo de Casos

Esta seção apresenta dois estudos de caso que visam analisar qualitativamente o comportamento do modelo em diferentes cenários de classificação. O primeiro caso refere-se a uma imagem de câncer seroso corretamente classificada (A), cuja visualização das regiões mais relevantes para a decisão do modelo, gerada pelo LIME, é apresentada em (B). O segundo caso corresponde a uma imagem de câncer endometriode classificada incorretamente (C), com sua respectiva visualização das regiões relevantes geradas pelo LIME apresentada em (D). Todas as imagens estão ilustradas na Figura 3.




Figura 3. Estudos de caso com visualizações LIME. (A) Imagem classificada corretamente como câncer seroso; (B) LIME de (A); (C) imagem endometriode classificada incorretamente como seroso; (D) LIME de (C).

Ao analisar o caso (A), observa-se, por meio das regiões destacadas nas explicações visuais geradas pelo LIME em (B), que determinados padrões histomorfológicos e características celulares influenciaram a decisão do classificador, indicando

que essas regiões foram consideradas relevantes para a predição da classe serosa [Soslow 2008]. No caso (C), cuja explicação é apresentada em (D), embora elementos relacionados à anormalidade estejam presentes, eles não são predominantes, o que pode ter dificultado a discriminação pelo modelo, levando à predição incorreta. A classe incorreta (seroso) foi atribuída com 32,33% de probabilidade, enquanto a classe correta (endometrióide) recebeu 31,21%, indicando baixa separabilidade entre as classes.

Apesar dessas limitações, os resultados quantitativos e as análises qualitativas indicam que o método proposto apresenta potencial como ferramenta de apoio ao diagnóstico médico, especialmente na identificação de padrões relevantes em imagens histopatológicas. Além disso, o uso do LIME contribui para aumentar a transparência do modelo, permitindo aos especialistas visualizar os fatores que influenciaram as predições e reforçando a confiabilidade do método como suporte à tomada de decisão clínica.

4.7. Comparação com Trabalhos Relacionados

Esta seção apresenta uma comparação entre o método proposto por este estudo e trabalhos recentes encontrados na literatura (Seção 2). Embora uma comparação quantitativa direta dos estudos existentes com o método proposto não seja possível devido a diferenças nos conjuntos de dados, protocolos de validação e configurações experimentais adotadas em cada estudo, o método proposto apresenta desempenho competitivo (Tabela 5).

Tabela 5. Comparação de trabalhos relacionados e do método proposto.

Trabalho	Método	ACC	PRE	SEN	ESP	F1-score
[Bikku et al. 2025]	Wiener + CLAHE + DenseNet121	95,30%	94,70%	95,00%	—	94,80%
[Alvino et al. 2025]	Escala de Cinza + VGG16 + SVM	94,99%	95,00%	95,15%	95,50%	95,00%
[Rahman et al. 2025]	DenseNet201	95,64%	95,63%	95,60%	98,80%	95,60%
[Tamanini et al. 2025]	YCrCb + Radiomics + I-RFE + RF	97,96%	96,69%	99,89%	95,42%	98,26%
[Alahmadi 2024]	ViT-Large-P32-384	98,86%	97,18%	97,06%	99,28%	97,09%
[El-Latif et al. 2024]	ResNet50 + RFE + Fuzzy	98,99%	99,00%	98,96%	—	98,99%
Método Proposto	Fusão de Canais + ResNet50 + SVM + LIME	97,96%	98,13%	97,96%	98,95%	97,95%

Diante dos resultados apresentados, observa-se que o método proposto alcança desempenho comparável aos trabalhos da literatura. Destaca-se que a abordagem adotada considera um cenário de classificação multiclasse, o que torna o problema mais desafiador em comparação a estudos que utilizam classificação binária [Bikku et al. 2025, Tamanini et al. 2025, Alvino et al. 2025, El-Latif et al. 2024]. Esse aspecto exige maior capacidade discriminativa do modelo, reforçando a relevância dos resultados obtidos na abordagem apresentada. Adicionalmente, a inclusão de uma classe saudável torna o problema mais realista e exigente, uma vez que o modelo precisa distinguir entre padrões normais e patológicos. Diferentemente de abordagens que consideram apenas classes doentes [Rahman et al. 2025], essa configuração amplia a complexidade do problema e aumenta a aplicabilidade da solução proposta.

Em relação aos trabalhos multiclasse com maiores métricas, como [Alahmadi 2024] e [El-Latif et al. 2024], observa-se que, embora apresentem acurácias superiores, o método proposto apresenta desempenho competitivo e, no caso de [Alahmadi 2024], supera os resultados em métricas como precisão, sensibilidade e F1-score. Esses resultados indicam um melhor equilíbrio na classificação entre as classes, aspecto relevante em cenários multiclasse, além de apresentar menor custo

computacional em comparação a arquiteturas mais complexas. Por fim, os resultados demonstram a eficácia da fusão de canais de cor na extração de *Deep Features* mais discriminativas nas imagens, combinada com a otimização do classificador usando Optuna e a explicabilidade visual fornecida pelo LIME, configurando uma alternativa eficiente e interpretável para aplicações clínicas.

5. Conclusão

A identificação precoce de subtipos de câncer de ovário é essencial para um diagnóstico preciso e para a definição de estratégias terapêuticas, sendo métodos computacionais promissores no apoio à tomada de decisões clínicas. Dentre os experimentos realizados, a abordagem baseada na fusão de canais, utilizando ResNet50 como extrator de *Deep Features* combinado com o classificador SVM com otimização de hiperparâmetros via Optuna e suporte de interpretabilidade por meio do LIME, apresentou o melhor desempenho, atingindo 97,96% de acurácia, 98,13% de precisão, 97,96% de sensibilidade, 98,95% de especificidade e 97,95% de F1-score. Esses resultados evidenciam bom desempenho geral e reforçam a eficácia da fusão de canais na melhoria da representação das características.

Para trabalhos futuros, recomenda-se o uso de novas bases de imagens para ampliar a variabilidade dos dados e avaliar a capacidade de generalização do modelo. Também sugere-se investigar estratégias mais avançadas de pré-processamento, bem como abordagens baseadas em *ensemble* de *Deep Features* e técnicas de seleção de características para aprimorar a representação dos dados e o desempenho da classificação. Além disso, propõe-se explorar arquiteturas mais recentes e aprendizado fim-a-fim, promovendo um treinamento mais integrado.

Agradecimentos

O presente trabalho foi realizado com apoio da Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Ainda, reconhecemos o uso do LLM para verificação ortográfica, correção gramatical e assistência na tradução de termos específicos.

Referências

- Alahmadi, A. (2024). Towards ovarian cancer diagnostics: A vision transformer-based computer-aided diagnosis framework with enhanced interpretability.
- Alvino, A., Alves, E., Brito, S., Nascimento, V., Cruz, L., Diniz, J., Jr, L. S., Silva, J., and Jr, D. G. (2025). Abordagem baseada em deep features para diagnóstico de câncer seroso de ovário em imagens histopatológicas. In *Anais do XXV Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 401–412, Porto Alegre, RS, Brasil. SBC.
- Beaufort, C. M. et al. (2014). Ovarian cancer cell line panel (occp): clinical importance of in vitro morphological subtypes. *PloS one*, 9(9):e103988.
- Bikku, T., Pujari, J. J., Satyasree, K., Thota, S., and Joseph, S. (2025). Deep learning-based ovarian cancer detection from histopathology images. *Quality & Quantity*, pages 1–15.
- El-Latif, E. I. A., El-Dosuky, M., Darwish, A., and Hassanien, A. E. (2024). A deep learning approach for ovarian cancer detection and classification based on fuzzy deep learning.

- Gonzalez, R. C. and Woods, R. E. (2010). *Modelos de Cores*. Pearson Prentice Hall, 3 edition.
- Instituto Nacional de Câncer (INCA) (2026). *Estimativa 2026: Incidência de Câncer no Brasil*. Instituto Nacional de Câncer, Rio de Janeiro, RJ, Brasil. Relatório técnico sobre estimativa de incidência de câncer no Brasil.
- Kasture, K. (2021). Ovariancancer & subtypes dataset histopathology. Mendeley Data, V1. Disponível em: <https://www.kaggle.com/datasets/bitsnpieces/ovarian-cancer-and-subtypes-dataset-histopathology>. Acesso em: 18 Fev. 2026.
- Mallya, M., Mirabadi, A. K., Farnell, D., Farahani, H., and Bashashati, A. (2025). Benchmarking histopathology foundation models for ovarian cancer bevacizumab treatment response prediction from whole slide images. *Discover Oncology*, 16(1):196.
- Pavel, C. D., Moldovanu, S., Pavel, I. A., Dragostin, O.-M., Chițescu, C. L., and Zamfir, C. L. (2025). Hybrid deep learning models for analyzing histological images of the zebrafish intestine under oxidative stress. *Diagnostics*, 15(22):2859.
- Peneira, C., Maciel, M. G., and de Lima, Á. M. (2025). O aumento de câncer em pacientes jovens. *UniLS Acadêmica*, 3(1):14–14.
- Rahman, M. M., Reem, S. Z., Rahaman, M. A., Bepery, C., Ashiqussalehin, M., Hosain, M. J., et al. (2025). Explainable transfer learning for histopathological image classification of ovarian cancer. *Journal of Technological Enquiry and Computer Miscellaneous*, 1(1).
- Rawi, A. A., Elbashir, M. K., and Ahmed, A. M. (2023). Deep learning models for multilabel ecg abnormalities classification: A comparative study using tpe optimization. *Journal of Intelligent Systems*, 32(1):20230002.
- Ribeiro, M. T., Singh, S., and Guestrin, C. (2016). ”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*, pages 1135–1144.
- Saha, A. K. et al. (2025). An enhanced deep learning model for accurate classification of ovarian cancer detection from histopathological images. *Scientific Reports*, 15(1):152180.
- Soslow, R. A. (2008). Histologic subtypes of ovarian carcinoma: an overview. *International Journal of Gynecological Pathology*, 27(2):161–174.
- Sung, H. et al. (2021). Global cancer statistics 2020: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries. 71(3):209–249.
- Tamanini, B. A. et al. (2025). Classificação de carcinoma endometriode de ovário por transformação de esquema de cor e radiomics em imagens histopatológicas. In *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*, pages 68–79. SBC.
- World Ovarian Cancer Coalition (2022). Ovarian cancer – key stats. <https://worldovariancancercoalition.org/about-ovarian-cancer/key-stats/>. Acessado: 18 Fev. 2026.