

Abordagem baseada em *Deep Features* para Diagnóstico de Câncer Seroso de Ovário em Imagens Histopatológicas

André F. Alvino¹, Edielson S. Alves¹, Sâmila S. Brito¹,
Victor T. Nascimento¹, Luana B. da Cruz², João O. B. Diniz¹,
Luiz O. O. Souza Jr¹, Josenildo C. da Silva¹, Daniel L. Gomes Jr¹

¹Synthesis Lab – Fábrica de Inovação
Instituto Federal do Maranhão (IFMA)

²Laboratório de Inteligência Computacional Aplicada (LICA)
Universidade Federal do Cariri (UFCA)

joao.bandeira@ifma.edu.br

Abstract. *Serous ovarian carcinoma (SOC) is an aggressive subtype of ovarian cancer with a challenging diagnosis in histopathological images. This work proposes an approach to define the optimal color scheme for image representation and extract Deep Features. The experiments demonstrated that the proposed method outperforms other Convolutional Neural Network (CNN)-based approaches, achieving 94.99% accuracy. Additionally, it proved effective in differentiating SOC from other subtypes, such as clear cell, endometrioid, and mucinous carcinomas. These results highlight the potential of the proposed approach to assist in SOC diagnosis, providing a promising tool for clinical decision support.*

Resumo. *O carcinoma seroso de ovário (CSO) é um subtipo agressivo de câncer de ovário com diagnóstico desafiador em imagens histopatológicas. Este trabalho propõe uma abordagem para definição do melhor esquema de cor que represente a imagem e extração de Deep Features. Os experimentos demonstraram que o método proposto supera outras abordagens baseadas em Rede Neural Convolutiva (CNN), atingindo 94,99% de acurácia. Além disso, mostrou-se eficaz na diferenciação do CSO em relação a outros subtipos, como células claras, endometrióide e mucinoso. Esses resultados evidenciam o potencial da abordagem proposta para auxiliar no diagnóstico do CSO, fornecendo uma ferramenta promissora para apoio à decisão clínica.*

1. Introdução

Entre as neoplasias malignas que acometem as mulheres, o câncer de ovário é o quinto mais comum e o segundo mais frequente entre os cânceres ginecológicos. No entanto, é o mais letal, evidenciado por uma taxa de sobrevivência em cinco anos de apenas 46%. Globalmente, aproximadamente 250.000 novos casos são diagnosticados anualmente, resultando em 140.000 óbitos. No Brasil, foram estimados 6.650 novos diagnósticos para o ano de 2020, com 4.123 mortes registradas em 2019 [Rodrigues et al. 2021]. Entre os subtipos epiteliais mais comuns de câncer de ovário, destacam-se os carcinomas serosos, endometrioides, de células claras e mucinosos. O carcinoma seroso é o subtipo histológico mais prevalente [Martelo et al. 2021].

O diagnóstico precoce é um fator essencial no manejo e controle da doença. As imagens histopatológicas do ovário, obtidas por meio de exames microscópicos, desempenham um papel fundamental na detecção e tratamento do câncer. Essas imagens revelam características morfológicas e moleculares que auxiliam na distinção entre condições benignas e malignas, contribuindo significativamente para a elaboração de um prognóstico individualizado e para o acompanhamento da evolução do tratamento [Appel et al. 2009]. No entanto, a análise manual dessas imagens, que envolve a avaliação do tipo celular, da extensão da invasão e do grau de diferenciação, é um processo complexo e suscetível à fadiga e à variabilidade diagnóstica, o que pode levar a erros [Diniz et al. 2024].

Diante desses desafios, a inteligência artificial vem desempenhando um papel fundamental no auxílio a especialistas da área médica, oferecendo diversos métodos computacionais para detecção [Diniz et al. 2023], segmentação [da Cruz et al. 2020, da Cruz et al. 2022], classificação [Junior et al. 2024, da S. Viana et al. 2024] e diagnóstico [Neto et al. 2024], entre outras tarefas [Gonçalves et al. 2024]. Além disso, vários estudos apontam que o uso de aprendizado profundo em imagens histopatológicas traz benefícios significativos para a detecção e classificação de diferentes tipos de câncer [Diniz et al. 2024, Carvalho et al. 2020].

Adicionalmente, a análise e classificação de imagens histopatológicas por médicos especialistas são processos complexos e demorados, o que resulta em bases de dados com quantidades reduzidas de amostras. Métodos baseados em Redes Neurais Convolucionais (CNNs), que tradicionalmente requerem grandes volumes de imagens para treinamento, podem ser prejudicados por essa limitação. Nesse contexto, abordagens baseadas em *Deep Features* têm se mostrado promissoras, especialmente devido à sua capacidade de generalização mesmo em cenários com conjuntos de dados reduzidos.

Assim, este trabalho tem como objetivo desenvolver uma abordagem baseada em *Deep Features* para a classificação do carcinoma seroso de ovário (CSO) em imagens histopatológicas. As principais contribuições desta pesquisa são:

- Definição de uma representação no espaço de cor que aprimora as características texturais para diferenciação do CSO de outras classes.
- Extração de *Deep Features* automatizada por várias arquiteturas, alcançando alta acurácia com eficiência computacional.

Com isso, esta pesquisa propõe uma solução eficaz e escalável para aprimorar a detecção precoce do CSO, oferecendo uma ferramenta valiosa para auxiliar patologistas na tomada de decisão clínica.

2. Trabalhos Relacionados

O câncer de ovário, sendo um dos tipos mais comuns e letais, tem motivado extensas pesquisas voltadas ao desenvolvimento de métodos computacionais que auxiliem especialistas em sua classificação. Dentre essas abordagens, destaca-se o uso de CNNs para a diferenciação dos subtipos histológicos. A literatura apresenta diversos estudos voltados ao diagnóstico dessa doença, os quais são discutidos nesta seção em relação ao método proposto.

O trabalho conduzido por [El-Bendary et al. 2018] propõem uma abordagem para classificar os subtipos do câncer epitelial de ovário, integrando dados clínicos com ex-

pressão gênica reduzida dimensionalmente. A seleção de características é feita por *Sequence Forward Selection*, e entre os classificadores testados, o Boosting obteve o melhor desempenho, alcançando 80% de acurácia.

Em [Wang et al. 2020], foi desenvolvido um método para a classificação do carcinoma epitelial de ovário em imagens de lâminas inteiras, utilizando aprendizado profundo por transferência com VGG19 e redimensionamento progressivo. O modelo, aplicado a cinco subtipos histológicos, atingiu 87,54% de acurácia e um coeficiente Kappa de 0,8106, superando o desempenho de CNNs convencionais.

No estudo de [Lakshmanan et al. 2023], foram utilizadas CNNs, como VGG16, VGG19 e AlexNet, para detectar e classificar subtipos de câncer de ovário em imagens histopatológicas, obtendo altos valores de acurácia, precisão, sensibilidade e F1-Score. Embora essas arquiteturas sejam distintas das empregadas neste trabalho, suas técnicas de extração de características são relevantes para a análise comparativa dos extratores adotados em nossa pesquisa. Já em [Sadeghi et al. 2024], foram exploradas CNNs como a ResNet, evidenciando o potencial do aprendizado profundo para aumentar a precisão e a eficiência diagnóstica, reforçando a predominância dessas arquiteturas no estado da arte.

Por fim, em [Abd El-Latif et al. 2024], foi proposto um modelo baseado em aprendizado profundo para a classificação do câncer de ovário em imagens histopatológicas, utilizando a ResNet50 como extrator de características. O estudo incorporou técnicas de aumento de dados (escala, espelhamento e rotação), seguido da seleção de características e classificação com lógica fuzzy, alcançando 98,99% de acurácia, 99% de sensibilidade e 98,96% de especificidade. Além de demonstrar a eficácia na distinção entre amostras cancerosas e não cancerosas, o estudo reforça a necessidade de estratégias de aumento de dados para melhorar a generalização dos modelos.

Diferentemente dos trabalhos anteriores, este estudo concentra-se especificamente na classificação do CSO. Conforme destacado por [Ferreira et al. 2012], o CSO é o subtipo mais prevalente e agressivo entre os cânceres epiteliais de ovário, representando mais de 80% dos casos e é o responsável pela maior taxa de mortalidade. Assim, diferenciá-lo corretamente dos demais subtipos é fundamental para auxiliar médicos especialistas na redução dessa estatística alarmante.

Desta forma, este trabalho propõe o uso de arquiteturas avançadas para a extração de *Deep Features*, aliada à aplicação de diferentes esquemas de cores como etapa de pré-processamento das imagens, uma abordagem ainda pouco explorada na literatura. Destaca-se a necessidade de investigar os esquemas de cores a fim de otimizar a representação das características tumorais.

Adicionalmente, muitos estudos utilizam diferentes CNNs sem uma análise criteriosa da escolha da arquitetura, tornando a seleção da mais adequada um desafio. Em contraste, este trabalho adota uma abordagem que compara diferentes arquiteturas e avalia o impacto dos esquemas de cor na extração de características. Além disso, enquanto muitas pesquisas exploram apenas arquiteturas CNN ou classificadores isoladamente, o presente estudo adota uma abordagem que combina CNNs para a extração de *Deep Features* e diversos classificadores tradicionais, como SVM, Random Forest, KNN, AdaBoost e xGBoost. Isto visa aprimorar a extração de características e o desempenho dos classificadores, contribuindo para um diagnóstico automatizado mais preciso e um suporte mais

eficiente aos profissionais da saúde.

3. Materiais e Método Proposto

Nesta seção, são apresentados os materiais e o método proposto. Primeiramente, descreve-se a base de dados utilizada para o desenvolvimento do modelo. Em seguida, são avaliados diferentes esquemas de cores para selecionar aquele que melhor representa as imagens de CSO. Após essa etapa, realiza-se a extração das *Deep Features* utilizando CNNs. Essas características extraídas são então empregadas no treinamento e teste dos classificadores. Por fim, métricas de validação são calculadas para avaliar o desempenho do método. A Figura 1 ilustra todas as etapas do processo.




Figura 1. Ilustração do método proposto.

3.1. Base de Dados

Para o desenvolvimento do método, utilizou-se a base de dados *Ovarian Cancer & Subtypes Dataset Histopathology* [Kasture 2021], que contém imagens histopatológicas de quatro subtipos de câncer de ovário (células claras, endometriode, mucinoso e seroso), além de amostras não cancerosas (NC). Cada classe possui 100 imagens no formato PNG, com dimensões variando entre 225 e 888 *pixels* de altura e 225 a 550 *pixels* de largura. As imagens foram redimensionadas para 224×224 *pixels*, tamanho comumente usado como entrada para as CNNs [Júnior et al. 2021].

Optou-se por utilizar as imagens do subtipo CSO devido à sua relevância clínica. O CSO é o subtipo mais prevalente e agressivo entre os cânceres epiteliais de ovário, representando aproximadamente 80% dos casos e sendo responsável pela maior taxa de mortalidade. Além disso, é frequentemente diagnosticado em estágios avançados, o que reduz significativamente as opções terapêuticas e impacta negativamente a sobrevida das pacientes [Ferreira et al. 2012]. Dessa forma, sua identificação precoce e caracterização precisa são essenciais para melhorar o prognóstico e auxiliar no planejamento terapêutico. A Figura 2 apresenta exemplos de imagens de CSO e de amostras NC.

3.2. Pré-processamento

A seleção do esquema de cor é uma etapa fundamental do processo, influenciando diretamente a qualidade das características extraídas pelos modelos computacionais [Diniz et al. 2024]. Diferentes esquemas de cor podem destacar ou suavizar aspectos específicos da imagem, afetando a capacidade do modelo de identificar padrões relevantes para a classificação. Portanto, a análise de múltiplos esquemas de cor é essencial para maximizar a eficácia da extração de características e, consequentemente, melhorar o desempenho do classificador.

Assim, foram analisados alguns dos esquemas de cores amplamente utilizados na literatura [Gonzalez and Woods 2018], sendo eles:




Figura 2. (A) Câncer Seroso de Ovário (CSO) e (B) Não Cancerígeno (NC).

- **RGB (*Red, Green, Blue*)**: o esquema mais comum em imagens digitais, representando cores como combinações de vermelho, verde e azul. Embora seja amplamente usado, pode não ser a melhor escolha para análise médica, pois não separa bem informações de intensidade luminosa e cor.
- **Escala de Cinza**: reduz a imagem a uma escala de cinza, eliminando a informação de cor e preservando apenas a intensidade luminosa. Essa abordagem pode ser útil para destacar contrastes estruturais e reduzir a complexidade do modelo, além de minimizar ruídos cromáticos.
- **XYZ**: baseado na percepção visual humana, esse espaço de cor é utilizado em aplicações que exigem alta precisão na representação de cores. Ele oferece uma modelagem mais fiel à forma como o olho humano percebe as variações de cor e luminosidade.
- **LUV (*Luminance, U, V*)**: é utilizado para representar a luminosidade (*L*) e as diferenças de cor em dois componentes (*U* e *V*). Este modelo é eficiente para tarefas que envolvem percepção de cor, pois é projetado para refletir melhor a forma como os humanos percebem as cores e a luminosidade. O LUV é útil em análise de imagens médicas, pois separa a luminância da cromaticidade e pode facilitar a segmentação e realce de estruturas.
- **HSV (*Hue, Saturation, Value*)**: representa a imagem em termos de matiz, saturação e brilho, separando a informação de cor da intensidade luminosa. Esse esquema é amplamente utilizado em processamento de imagens médicas, pois facilita a segmentação de estruturas específicas.
- **LAB**: divide a imagem em três componentes: *L* (luminosidade), *A* (variação entre verde e vermelho) e *B* (variação entre azul e amarelo). Esse esquema é frequentemente utilizado para realce de contraste e processamento de texturas.

A Figura 3 destaca uma imagem de CSO com a representação nos esquemas de cores apresentados. Para decidir o melhor esquema de cor, é utilizado um teste inicial com uma CNN simples e seleciona aquele esquema de cor que apresenta o melhor resultado. Na Seção 4 é descrito os resultados encontrados para todos os esquemas.

3.3. Extração de *Deep Features*

Após a escolha do melhor esquema de cor, o próximo passo consiste em selecionar a arquitetura mais adequada para a extração das *Deep Features*. O uso desta técnica é

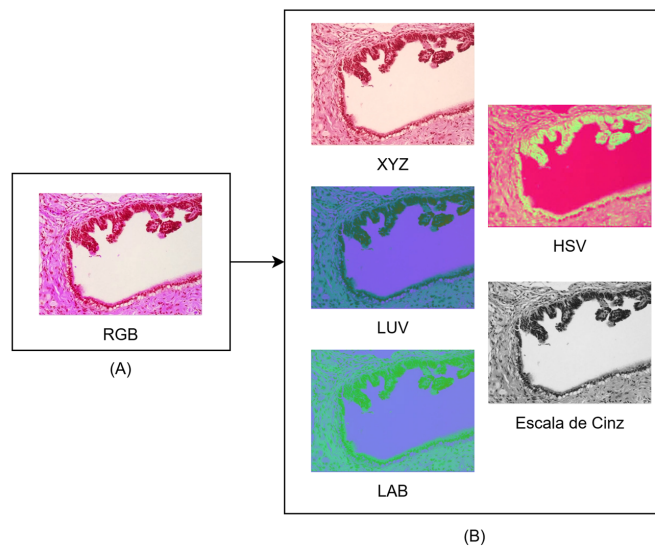


Figura 3. (A) Imagem original em RGB e (B) Demais esquemas.

motivada pela sua capacidade de capturar representações hierárquicas das imagens, extraíndo automaticamente padrões relevantes em diferentes níveis de abstração. Esse processo elimina a necessidade de seleção manual de características, tornando a abordagem mais eficiente e reduzindo a influência de vieses humanos. Além disso, as *Deep Features* apresentam maior capacidade de generalização, permitindo a reutilização de modelos pré-treinados e facilitando a transferência de aprendizado para novos conjuntos de dados e problemas específicos [Júnior et al. 2021].

Para garantir uma avaliação abrangente, foram testadas diferentes arquiteturas de CNNs amplamente utilizadas na literatura para extração de *Deep Features*:

- **VGG16**: modelo profundo composto por 16 camadas treináveis, conhecido por sua arquitetura simples e eficaz na extração de padrões espaciais complexos.
- **EfficientNetB0**: rede projetada para otimizar o desempenho com menor custo computacional, combinando convoluções eficientes e escalabilidade balanceada.
- **ResNet50**: arquitetura baseada em conexões residuais, permitindo treinamentos mais profundos ao mitigar o problema do desaparecimento do gradiente.
- **MobileNetV2**: modelo leve, otimizado para dispositivos móveis e aplicações com restrição de hardware, mantendo um bom equilíbrio entre precisão e eficiência computacional.
- **InceptionV3**: rede avançada que utiliza módulos *Inception*, permitindo a extração de características em múltiplas escalas e aumentando a diversidade dos filtros convolucionais.

3.4. Classificação

Após a extração das *Deep Features*, diferentes classificadores foram avaliados para determinar aquele que melhor representa o método proposto. A escolha do classificador adequado é uma etapa necessário, pois influencia diretamente o desempenho da classificação e a capacidade do modelo de generalizar para novos dados.

Foram testados classificadores amplamente utilizados na literatura para tarefas de reconhecimento de padrões e aprendizado supervisionado [Carvalho et al. 2020].

Destaca-se que por ser uma análise experimental, optou-se por usar todas as características geradas pelas arquiteturas, sem o uso inicial de seleção de características.

- **Support Vector Machine (SVM)**: modelo baseado na maximização da margem de separação entre classes, eficiente para conjuntos de dados com alta dimensionalidade.
- **Random Forest (RF)**: algoritmo de aprendizado baseado em múltiplas árvores de decisão, que melhora a robustez e reduz o risco de sobreajuste (*overfitting*).
- **XGBoost**: variante otimizada de árvores de decisão, que utiliza o princípio do *gradient boosting* para melhorar a precisão da classificação.
- **AdaBoost**: modelo baseado em aprendizado adaptativo, que combina múltiplos classificadores fracos para formar um modelo mais robusto.
- **K-Nearest Neighbors (KNN)**: método baseado na proximidade entre amostras, onde a classe de uma nova instância é definida pelos vizinhos mais próximos no espaço de características.

Cada classificador foi treinado e testado com as *Deep Features* extraídas das arquiteturas de CNN selecionadas, permitindo uma análise comparativa de desempenho para determinar a melhor combinação de extrator de características e classificador.

3.5. Métricas de Validação

Para avaliar o desempenho do método proposto, foram utilizadas métricas de validação amplamente empregadas em problemas de classificação. São elas: acurácia (ACC), especificidade (ESP), sensibilidade (SEN), precisão (PRE), F1-Score, coeficiente Kappa e área sob a curva ROC (AUC).

4. Resultados e Discussão

Esta seção apresenta os experimentos para definição do método por completo. Serão apresentados o ambiente de desenvolvimento, os experimentos para validar cada uma das etapas e a comparação entre o método e outros subtipos e as CNNs tradicionais.

4.1. Ambiente de Desenvolvimento

Os experimentos foram executados em um computador com as seguintes configurações: Intel® Core™ i7-12700H @ 2.30GHz, GPU Nvidia RTX-2060 6GB, 8GB de RAM e sistema operacional Windows 11. A implementação foi na linguagem Python, com uso de bibliotecas como Numpy, Pandas, OpenCV, Skicit-Learn e Keras. Pelo fato da base de dados ser pequena e para evitar sobreajuste, os experimentos foram realizados a partir de validação cruzada *k-fold*, com $k = 5$, onde cada iteração utilizou 80% dos dados para treino e 20% para teste. Os resultados apresentados são a média dos 5 *folds*.

4.2. Avaliação dos Esquemas de Cores

Para determinar o esquema de cor mais adequado à representação do CSO, utilizou-se a arquitetura VGG16 para extração de características e o classificador RF. Essa escolha foi feita exclusivamente para avaliar o impacto do esquema de cor, mantendo todos os hiperparâmetros definidos como padrão nas bibliotecas utilizadas. Os resultados obtidos estão apresentados na Tabela 1.

Tabela 1. Comparação de esquemas de cores com VGG16 + RF.

Esquema	ACC	ESP	SEN	PRE	F1-Score	Kappa	AUC
RGB	85,00%	85,71%	84,21%	84,21%	84,21%	69,92%	84,96%
Escala de Cinza	92,50%	95,24%	89,47%	94,44%	91,89%	84,92%	92,36%
XYZ	90,00%	95,24%	84,21%	94,12%	88,89%	79,85%	89,72%
LUV	85,00%	90,48%	78,95%	88,24%	83,33%	69,77%	84,71%
HSV	85,00%	85,71%	84,21%	84,21%	84,21%	69,92%	84,96%
LAB	83,00%	95,24%	68,42%	92,86%	78,79%	64,47%	81,83%

Os resultados demonstram que o esquema de cor impacta diretamente o desempenho da classificação. O melhor desempenho foi obtido com imagens em escala de cinza, superando os demais esquemas em todas as métricas avaliadas. Em comparação, o espaço de cor XYZ também apresentou resultados competitivos, mas o escala de cinza obteve um desempenho superior, com um aumento de mais de 2% em todas as métricas. Esses resultados indicam que a conversão para escala de cinza pode melhorar a extração de características relevantes para a detecção do CSO.

4.3. Avaliação dos Classificadores

Após a definição do esquema de cor, as *Deep Features* extraídas pela VGG16 foram utilizadas para treinar os classificadores apresentados na Seção 3. Todos os hiperparâmetros utilizados foram os padrões das bibliotecas empregadas. A Tabela 2 apresenta os resultados obtidos.

Tabela 2. Desempenho dos classificadores utilizando Escala de Cinza + VGG16.

Classificador	ACC	ESP	SEN	PRE	F1-Score	Kappa	AUC
KNN	70,34%	90,48%	47,37%	81,82%	60,00%	38,62%	68,92%
AdaBoost	83,00%	90,48%	73,68%	87,50%	80,00%	64,65%	82,08%
XGBoost	90,00%	90,48%	89,47%	89,47%	89,47%	79,95%	89,97%
SVM	94,99%	95,00%	95,15%	95,00%	95,00%	90,00%	94,96%
RF	92,50%	95,24%	89,47%	94,44%	91,89%	84,92%	92,36%

Os resultados mostram que os classificadores SVM e RF tiveram os melhores desempenhos. Como as classes estão equilibradas (100 amostras para cada classe), a acurácia é um bom indicador global, e o SVM se destacou nessa métrica. Além disso, apresentou a maior sensibilidade, essencial para identificar corretamente os casos positivos, e o maior F1-Score, evidenciando um equilíbrio entre precisão e sensibilidade. Seu alto AUC reforça sua capacidade discriminativa, tornando-o a escolha mais adequada para a classificação do CSO.

4.4. Seleção da *Deep Features*

Agora, com o esquema de cor (Escala de Cinza) e o classificador (SVM) definidos, o próximo passo é identificar a melhor arquitetura para extração das *Deep Features*. A Tabela 3 apresenta os resultados.

Os resultados indicam que tanto a VGG16 quanto a EfficientNetB0 apresentaram métricas de validação robustas. No entanto, ao considerar a acurácia juntamente com

Tabela 3. Esquema de Cor Escala de Cinza + Todas as CNNs + Classificador SVM.

CNN	ACC	ESP	SEN	PRE	F1-Score	Kappa	AUC
MobileNetV2	75,00%	95,00%	55,00%	91,67%	68,75%	50,00%	75,00%
VGG16	94,99%	95,00%	95,15%	95,00%	95,00%	90,00%	94,96%
EfficientNetB0	92,50%	95,15%	90,00%	94,74%	92,31%	85,00%	92,50%
ResNet50	85,00%	75,00%	95,00%	79,17%	86,36%	70,00%	85,00%
InceptionV3	75,00%	90,00%	60,00%	85,71%	70,59%	50,00%	75,00%

as demais métricas, a VGG16 se destaca como a melhor arquitetura, exceto na especificidade. Dessa forma, o método fica completamente definido com a Escala de Cinza como melhor esquema de cor, a VGG16 como melhor arquitetura para extração de *Deep Features* e o SVM como melhor classificador.

Os resultados obtidos são expressivos, alcançando valores de 95% em quase todas as métricas. Isso demonstra que o uso de *Deep Features* é uma estratégia eficaz para a classificação de CSO, especialmente em cenários onde a base de dados é pequena e contém um número reduzido de amostras.

4.5. CSO vs. Outros Subtipos

Por fim, com o método definido, buscou-se avaliar sua capacidade de diferenciar o CSO de outros subtipos de câncer de ovário descritos na base de dados [Kasture 2021]. A Tabela 4 descreve o experimento, no qual o modelo foi treinado para classificar CSO contra os subtipos células claras, endometriode, mucinoso e também contra tecidos NC.

Tabela 4. Desempenho do método na diferenciação entre CSO e outros subtipos de câncer de ovário.

Tipo	ACC	ESP	SEN	PRE	F1-Score	Kappa	AUC
Células Claras	85,00%	99,99%	71,43%	99,99%	83,33%	70,37%	85,71%
Endometriode	92,50%	84,21%	99,99%	87,50%	93,33%	84,85%	92,11%
Mucinoso	82,50%	89,47%	76,19%	88,89%	82,05%	65,17%	82,83%
Não Canceroso	94,99%	95,00%	95,15%	95,00%	95,00%	90,00%	94,96%

Os resultados mostram que, embora o método tenha sido inicialmente desenvolvido para diferenciar células do subtipo CSO de NC, a representação de esquema de cor e as *Deep Features* também foram eficazes na distinção entre outros diferentes subtipos de câncer de ovário. Isso sugere a robustez do modelo e sua potencial aplicabilidade em cenários mais amplos de diagnóstico e classificação tumoral, servindo como um aliado aos médicos especialistas.

4.6. Comparação com Redes Neurais Convolucionais

Finalmente, foi realizado uma comparação com diferentes arquiteturas de CNN amplamente utilizadas nos trabalhos relacionados da Seção 2. Como esses trabalhos não apresentam uma classificação direta entre CSO e NC, optou-se por esse experimento. As arquiteturas MobileNetV2, VGG16, EfficientNetB0, ResNet50 e InceptionV3 foram utilizadas, sendo modelos pré-treinados com a base ImageNet e as configurações padrão da

Tabela 5. Comparação do método proposto com outras CNNs.

Método	ACC	ESP	SEN	PRE	F1-Score	Kappa	AUC
MobileNetV2	82,50%	85,00%	80,00%	84,50%	82,18%	75,00%	83,00%
VGG16	85,00%	86,50%	83,50%	85,75%	84,61%	78,50%	85,30%
EfficientNetB0	86,00%	87,00%	84,50%	86,25%	85,36%	80,00%	86,50%
ResNet50	83,50%	85,75%	82,00%	84,80%	83,38%	76,00%	84,25%
InceptionV3	81,50%	83,25%	80,75%	82,10%	81,41%	74,00%	82,00%
Método Proposto	94,99%	95,00%	95,15%	95,00%	95,00%	90,00%	94,96%

biblioteca Keras. Os resultados estão apresentados na Tabela 5, comparando o método proposto com essas arquiteturas.

Os resultados indicam que o método proposto supera significativamente todas as outras abordagens testadas. Observa-se que, enquanto as arquiteturas CNN convencionais apresentam desempenho entre 81,50% e 86% em termos de acurácia, o método proposto alcança 94,99%, uma melhoria expressiva em relação às demais técnicas. Além disso, o método proposto se destaca nas demais métricas, indicando ser um modelo equilibrado e eficaz. Vale destacar que a base de dados possuía apenas 100 amostras de cada classe, que no contexto de CNN pode ser uma dificuldade no treinamento destas redes.

O principal diferencial do método proposto está na combinação otimizada de técnicas. O uso da Escala de Cinza reduziu a dimensionalidade dos dados, eliminando informações redundantes de cor que poderiam introduzir ruído no treinamento. A extração de *Deep Features* com a VGG16 permite capturar representações discriminativas mais relevantes para a classificação, e a escolha do SVM como classificador maximiza a separabilidade das classes, melhorando o desempenho geral.

Dessa forma, os experimentos reforçam que a abordagem proposta é eficaz e apresenta um excelente equilíbrio entre as métricas e a generalização, sendo uma alternativa promissora para tarefas de classificação de CSO em imagens histopatológicas, especialmente em contextos com bases de dados reduzidas.

5. Considerações Finais

Este trabalho apresentou uma abordagem baseada na extração de *Deep Features* para a classificação do CSO em imagens histopatológicas. A combinação da Escala de Cinza, extração de características com VGG16 e classificação com SVM resultou em um modelo eficiente, superando outras arquiteturas convencionais e atingindo 94,99% de acurácia. Além disso, demonstrou-se capaz de diferenciar células de CSO de NC, mas também distintos subtipos de câncer de ovário, evidenciando seu potencial para apoio no diagnóstico precoce.

Como trabalhos futuros, propõe-se a otimização de hiperparâmetros para refinar o desempenho do classificador, a avaliação do método em outras bases de dados para testar sua generalização e a exploração de diferentes esquemas de cores, para investigar seu impacto na extração de características. Essas direções podem contribuir para aprimorar a técnica e ampliar sua aplicabilidade no diagnóstico assistido por computador.

Agradecimentos

Este trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Code 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e da Fundação de Amparo à Pesquisa do Maranhão (FAPEMA). Reconhecemos também o uso de um LLM para revisão do texto.

Referências

- Abd El-Latif, E. I., 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. *Scientific Reports*, 14(26463).
- Appel, M., Monego, H. I., Ramos, J. G. L., Poli, M. E., Stein, A. T., Silva, J. M., Bernd, F. F., and Bersch, G. P. (2009). Screening and diagnosis of ovarian cancer. *AMRIGS Journal*, 53:1.
- Carvalho, E. D., Antonio Filho, O., Silva, R. R., Araujo, F. H., Diniz, J. O., Silva, A. C., Paiva, A. C., and Gattass, M. (2020). Breast cancer diagnosis from histopathological images using textural features and cbir. *Artificial intelligence in medicine*, 105:101845.
- da Cruz, L. B., Araújo, J. D. L., Ferreira, J. L., Diniz, J. O. B., Silva, A. C., de Almeida, J. D. S., de Paiva, A. C., and Gattass, M. (2020). Kidney segmentation from computed tomography images using deep neural network. *Computers in Biology and Medicine*, 123:103906.
- da Cruz, L. B., Júnior, D. A. D., Diniz, J. O. B., Silva, A. C., de Almeida, J. D. S., de Paiva, A. C., and Gattass, M. (2022). Kidney tumor segmentation from computed tomography images using deeplabv3+ 2.5 d model. *Expert Systems with Applications*, 192:116270.
- da S. Viana, P., da Cruz, L. B., Dias Jr, D. A., and Diniz, J. O. B. (2024). Anomalies diagnostic in endoscopic images using deep learning ensemble models. In *Brazilian Conference on Intelligent Systems*, pages 110–124. Springer.
- Diniz, J. O., Quintanilha, D. B., de Carvalho Filho, A. O., Gomes Jr, D. L., Silva, A. C., Braz Jr, G., de Paiva, A. C., and Luz, D. d. S. (2023). Detecção de covid-19 em imagens de raio-x de tórax através de seleção automática de pré-processamento e de rede neural convolucional. In *Anais do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 162–173. SBC.
- Diniz, J. O., Ribeiro, N. P., Junior, D. A. D., da Cruz, L. B., de Carvalho Filho, A. O., Gomes Jr, D. L., Silva, A. C., and de Paiva, A. C. (2024). Efficientxyz-deepfeatures: seleção de esquema de cor e arquitetura deep features na classificação de câncer de cólon em imagens histopatológicas. In *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*, pages 82–93. SBC.
- El-Bendary, N., Belal, N. A., et al. (2018). Epithelial ovarian cancer stage subtype classification using clinical and gene expression integrative approach. *Procedia Computer Science*, 131:23–30.
- Ferreira, P. A. R., Sallum, L. F. T. A., Sarian, L. O., Andrade, L. A., and Derchain, S. (2012). Carcinoma de ovário seroso e não seroso: tipo histológico em relação ao

- grau de diferenciação e prognóstico. *Revista Brasileira de Ginecologia e Obstetrícia*, 34:196–202.
- Gonzalez, R. C. and Woods, R. E. (2018). *Digital Image Processing*. Pearson, 4th edition.
- Gonçalves, J., Souza, D., Santos, C., Nascimento, C., Cruz, L., Junior, D. D., and Diniz, J. (2024). Diagnóstica: Ferramenta cadx para diagnóstico de doenças pulmonares em imagens radiológicas. In *Anais do XXIV Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 214–225, Porto Alegre, RS, Brasil. SBC.
- Júnior, D. A. D., da Cruz, L. B., Diniz, J. O. B., da Silva, G. L. F., Junior, G. B., Silva, A. C., de Paiva, A. C., Nunes, R. A., and Gattass, M. (2021). Automatic method for classifying covid-19 patients based on chest x-ray images, using deep features and pso-optimized xgboost. *Expert Systems with Applications*, 183:115452.
- Junior, D. D., Cruz, L., and Diniz, J. (2024). Classificação da camada lipídica do filme lacrimal usando k-means e deep learning. In *Anais do XXIV Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 1–12, Porto Alegre, RS, Brasil. SBC.
- Júnior, D. A. D., da Cruz, L. B., Diniz, J. O. B., da Silva, G. L. F., Junior, G. B., Silva, A. C., de Paiva, A. C., Nunes, R. A., and Gattass, M. (2021). Automatic method for classifying covid-19 patients based on chest x-ray images, using deep features and pso-optimized xgboost. *Expert Systems With Applications*, 183.
- Kasture, K. (2021). Ovarian cancer & subtypes dataset histopathology.
- Lakshmanan, S., Nagaraja, P., Rani, M. M. S., and Shanmugavadivu, P. (2023). Deep convolutional neural network for the prediction of ovarian cancer. In *Combating Women's Health Issues with Machine Learning*, pages 107–115. CRC Press.
- Martelo, M. P., López, V. C., González, M. M., and Bañuelos, J. C. (2021). Câncer de ovário. *Medicine - Programa de Formación Médica Continuada Acreditado*, 13(27).
- Neto, C. M. S., Silva, A. L., Pessoa, A. C., Quintanilha, D. B., de Almeida, J. D., Junior, G. B., and Diniz, J. O. (2024). Diagnóstico de tuberculose em imagens de radiografia utilizando cvt. In *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*, pages 342–353. SBC.
- Rodrigues, G. J. R., Lasmar, A. L. T., Rezende, B. E. S., Martins, B. C. S., Mussi, H. G., Rabello, L. N., Campagnani, S. M., and Santos, K. F. (2021). The relevance of implementing an ovarian cancer screening program: a narrative review. *Electronic Journal of Health Archive*, 13:1.
- Sadeghi, M. H., Sina, S., Omid, H., Farshchitabrizi, A. H., and Alavi, M. (2024). Deep learning in ovarian cancer diagnosis: a comprehensive review of various imaging modalities. *Polish journal of radiology*, 89:e30.
- Wang, Y., Farnell, D., Farahani, H., Nursey, M., Tessier-Cloutier, B., Jones, S. J. M., Huntsman, D. G., Gilks, C. B., and Bashashati, A. (2020). Classification of epithelial ovarian carcinoma whole-slide pathology images using deep transfer learning. *Medical Imaging with Deep Learning (MIDL) 2020 - Short Paper*.