

Classificação de Carcinoma Endometrioide de Ovário por Transformação de Esquema de Cor e Radiomics em Imagens Histopatológicas

Breno A. Tamanini¹, Víctor G. O. Sousa¹, Lissandro P. S. C. Rodrigues¹,
Danilo M. Oliveira¹, Calebe X. Dias¹, Luana B. da Cruz²,
João O. B. Diniz¹, Luiz O. O. Souza Júnior¹

¹Fábrica de Inovação — Instituto Federal do Maranhão (IFMA)
CEP 65940-000 — Grajaú — MA

²Laboratório de Inteligência Computacional Aplicada (LICA) —
Universidade Federal do Cariri (UFCA)
CEP 63.048-080 — Juazeiro do Norte — CE

joao.bandeira@ifma.edu.br

Abstract. *Endometrioid ovarian carcinoma (EOC) is a subtype of ovarian cancer with a challenging diagnosis in histopathological images. Convolutional Neural Networks (CNNs) are widely used for this task but require large amounts of data and high computational burden. This work proposes an approach based on color scheme transformation, Radiomics, and incremental feature selection (I-RFE), applied to multiple classifiers. The experiments showed that the proposed method outperforms CNNs in the literature, achieving an accuracy of 97.96% and an F1-Score of 98.26%, while the best CNN reached 75% accuracy. These findings suggest that the approach can improve EOC detection, making it a promising alternative for diagnostic support.*

Resumo. *Carcinoma endometrioide de ovário (CEO) é um subtipo do câncer de ovário com diagnóstico desafiador em imagens histopatológicas. Redes neurais convolucionais (CNNs) são amplamente utilizadas nessa tarefa, mas exigem grandes volumes de dados e alta carga computacional. Este trabalho propõe uma abordagem baseada em transformação de esquema de cor, Radiomics, e seleção incremental de características (I-RFE), aplicada em vários classificadores. Os experimentos mostraram que o método proposto supera CNNs da literatura, alcançando uma acurácia de 97,96% e F1-Score de 98,26%, enquanto a melhor CNN obteve 75% de acurácia. Esses achados sugerem que a abordagem pode aprimorar a detecção de CEO, tornando-se uma alternativa promissora no auxílio ao diagnóstico precoce.*

1. Introdução

O câncer de ovário é a sexta neoplasia maligna mais diagnosticada em mulheres, correspondendo a aproximadamente 4% dos casos globais [Reid et al. 2017]. Dentre os carcinomas ginecológicos, destaca-se como um dos mais prevalentes, ficando atrás apenas do câncer do corpo uterino. De acordo com [Chaturvedi et al. 2023], a incidência global dessa neoplasia pode atingir 400 mil novos casos até 2040, tornando-se um desafio significativo para a saúde pública.

A complexidade do câncer de ovário está associada à sua heterogeneidade, caracterizada pela disseminação de tumores malignos que podem surgir a partir de células epiteliais, estromais ou germinativas. Entre os subtipos epiteliais mais comuns, destacam-se os carcinomas serosos, endometrioides, de células claras e mucinosos [Reid et al. 2017]. O carcinoma endometrioido de ovário (CEO) destaca-se devido à sua correlação com alterações hormonais e associação com hiperplasia endometrial, além de apresentar uma resposta terapêutica distinta em relação a outros subtipos [Leyland et al. 2010]. Além disso, os CEO assemelham-se morfologicamente às neoplasias endometrioides uterinas e podem ser classificados erroneamente em benignos e limítrofes [Wong et al. 2024].

A detecção e diagnóstico do CEO são desafiadores, sendo frequentemente realizadas por meio de imagens histopatológicas. No entanto, a análise dessas imagens e a diferenciação entre tecidos malignos, outras patologias e tecido saudável são processos complexos e suscetíveis a erros devido à subjetividade na interpretação. Com o avanço da Inteligência Artificial, diversos métodos têm sido desenvolvidos para auxiliar médicos especialistas na detecção de patologias por meio da análise automatizada de imagens [Diniz et al. 2023, Gonçalves et al. 2024, Diniz et al. 2024a].

A coloração de Hematoxilina e Eosina (H&E) é amplamente usada em imagens histopatológicas, onde a hematoxilina cora os núcleos celulares em tons de azul a roxo, enquanto a eosina cora o citoplasma e a matriz extracelular em tons de rosa a vermelho [Carvalho et al. 2020]. Essa técnica destaca estruturas celulares e variações histológicas, auxiliando no diagnóstico de diversas patologias, como o CEO. No contexto do processamento de imagens para análise de textura, outras representações de cores podem ser mais eficazes para distinguir tecidos não cancerígenos (NC) e cancerígenos. Neste sentido, alterações nos esquemas de cores podem realçar padrões específicos e a distribuição celular, tornando a extração de características mais robustas [Diniz et al. 2024b].

Além disso, dentro das técnicas de análise de imagens, a abordagem de Radiomics tem sido aplicada na oncologia para extraer características quantitativas em larga escala. Essa técnica permite capturar informações sutis de textura, forma e intensidade, muitas vezes imperceptíveis visualmente, aumentando a precisão na diferenciação entre tecidos malignos e não malignos. Os dados extraídos são então utilizados em modelos de aprendizado de máquina para classificação e auxílio diagnóstico [Neto et al. 2018].

Assim, este trabalho propõe um método para classificar o CEO, explorando a influência de esquemas de cores na extração de características texturais. Além disso, investiga a eficácia da técnica de Radiomics na distinção entre CEO e NC, usando múltiplos classificadores de aprendizado de máquina. Acredita-se que essa abordagem pode melhorar a acurácia da detecção do CEO e contribuir para o desenvolvimento de ferramentas de apoio ao diagnóstico. Este estudo busca avançar na área, contribuindo para:

- Melhorar a extração de características texturais por meio da análise de diferentes esquemas de cores;
- Explorar a técnica de Radiomics pela primeira vez na classificação do CEO, avaliando sua eficácia na extração de características discriminantes em diferentes esquemas de cores.

2. Trabalhos Relacionados

A literatura apresenta diversos estudos voltados ao diagnóstico de câncer de ovário, com ênfase no uso de redes neurais convolucionais (CNNs) para diferenciar seus subtipos. Embora não seja possível fazer uma comparação direta dos estudos existentes com o método em termos quantitativos, uma vez que nenhum deles foca especificamente na classificação de CEO, tais trabalhos refletem as técnicas utilizadas na literatura para tarefas semelhantes.

[Lakshmanan et al. 2023] destacam a alta taxa de mortalidade do câncer de ovário e a importância de sua detecção precoce. O estudo investiga o uso de três arquiteturas de CNNs profundas (VGG16, VGG19 e AlexNet) para a classificação automática de subtipos de câncer de ovário a partir de imagens histopatológicas. [Radhakrishnan et al. 2024] propõem um modelo baseado em redes neurais profundas para classificar os subtipos de câncer de ovário. O trabalho avalia diferentes arquiteturas, incluindo MobileNetV2, VGG19, ResNet18, ResNeXt, Xception, EfficientNet e InceptionV3, sendo esta última a de melhor desempenho.

Já em [Pavithra et al. 2024], apresentam o modelo KK-Net, baseado em aprendizado profundo, para a classificação de quatro subtipos de câncer de ovário. Por fim, [Ifty et al. 2025] desenvolveram uma abordagem baseada em CNNs, comparando arquiteturas, como: LeNet-5, ResNet, VGGNet e GoogLeNet/Inception. Os estudos reforçam a necessidade de métodos mais eficazes para a detecção não invasiva do câncer de ovário.

Os trabalhos recentes utilizam majoritariamente aprendizado profundo, com foco em CNNs tradicionais já aplicadas a diversos problemas. No entanto, nenhum deles explora modificações nos esquemas de cores ou o uso de Radiomics para análise do CEO. O método proposto neste trabalho busca introduzir a abordagem de Radiomics para CEO, possibilitando a extração de atributos quantitativos que capturam padrões sutis nas imagens médicas, aprimorando a análise antes da classificação final. Além disso, diferencia-se ao aplicar transformações no esquema de cor das imagens como etapa de pré-processamento, um aspecto ainda não explorado na literatura. Essa estratégia pode potencialmente aumentar a robustez dos modelos, especialmente em cenários clínicos, onde a variabilidade dos dados pode impactar diretamente a acurácia dos diagnósticos.

3. Materiais e Método Proposto

O método proposto é dividido em cinco etapas principais. A primeira etapa consiste na descrição da base de dados, seguida pela definição dos esquemas de cores utilizados no trabalho. Posteriormente, as características são extraídas por meio da técnica de Radiomics, e as mais relevantes são selecionadas utilizando um método incremental baseado na Eliminação Recursiva de Características (*Recursive Feature Elimination - RFE*). Por fim, é realizada a classificação entre CEO e NC, calculando as métricas de validação. A Figura 1 ilustra estas etapas, que são detalhadas a seguir.

3.1. Base de Dados

A base de dados utilizada neste trabalho foi a *Ovarian Cancer & Subtypes Dataset Histopathology* [Kasture 2021], que contém imagens histopatológicas de quatro subtipos de câncer de ovário, além de amostras NC. Os subtipos disponíveis são: câncer de células claras, CEO, câncer mucinoso e câncer seroso, cada um com 100 imagens no formato

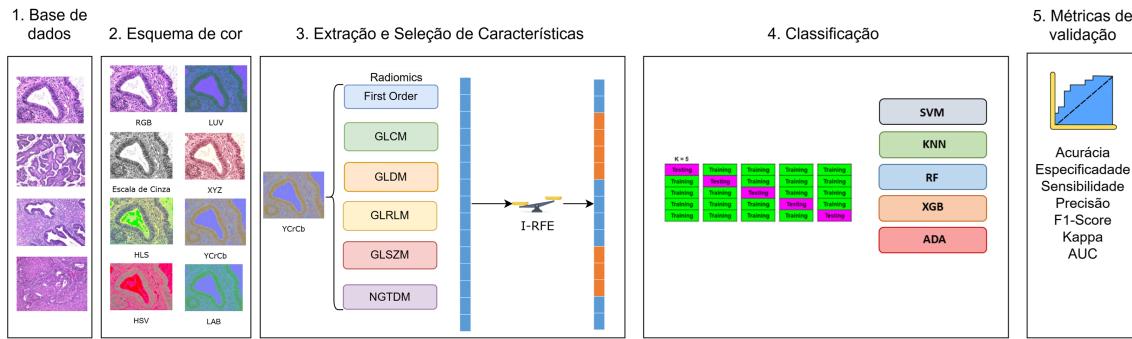


Figura 1. Etapas do método proposto.

PNG. Neste estudo, optou-se por utilizar as imagens do subtipo CEO, devido à sua relevância clínica e características morfológicas específicas, que apresentam desafios distintos na classificação automatizada. Esse carcinoma é um dos tipos mais comuns de câncer de ovário, tornando sua identificação precoce e caracterização precisa essenciais para aprimorar o prognóstico e o planejamento terapêutico. A Figura 2 apresenta exemplos de imagens de NC e CEO.

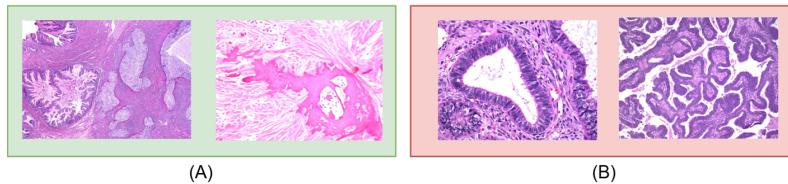


Figura 2. (A) Não Cancerígeno (NC) e (B) Câncer Endometrioide de Ovário (CEO).

3.2. Esquema de Cor

Sabe-se que, para os modelos de visão computacional, a representação da imagem pode ser fundamental para melhorar as etapas de classificação do método. Dependendo de qual esquema de cor uma imagem é representada, as características texturais podem ser melhor preservadas, impactando positivamente as etapas de extração de características e classificação [Carvalho et al. 2020, Diniz et al. 2024b]. Neste trabalho, propõe-se avaliar qual é o melhor esquema de cor para as imagens de CEO. Assim, foram analisados oito esquemas de cores amplamente utilizados na literatura [Gonzalez and Woods 2008], sendo eles:

- **RGB (Red, Green, Blue):** modelo de cores aditivas, representando diretamente os componentes vermelho, verde e azul da imagem.
- **LUV (CIE-LUV):** modelo perceptual que separa a luminância (L) das componentes cromáticas (U e V), garantindo maior uniformidade na percepção de cores.
- **Escala de cinza:** representação monocromática onde cada pixel armazena um valor entre 0 (preto) e 255 (branco), indicando a intensidade luminosa da imagem.
- **XYZ (CIE-XYZ):** modelo de cores baseado na percepção humana, utilizado como referência para conversões entre diferentes espaços de cores.
- **HLS (Hue, Lightness, Saturation):** representação cilíndrica da cor baseada no matiz (*H*), luminosidade (*L*) e saturação (*S*), útil para segmentação e detecção de padrões texturais.

- **YCrCb**: modelo de cores utilizado em compressão de imagens e vídeos, separando a luminância (Y) das componentes cromáticas (Cr e Cb), sendo robusto a variações de iluminação.
- **HSV (Hue, Saturation, Value)**: modelo que separa matiz (*H*), saturação (*S*) e valor (*V*), útil para segmentação e análise de cores invariantes à iluminação.
- **LAB (CIE-LAB)**: espaço de cores perceptualmente uniforme, separando a luminância (*L*) das componentes cromáticas (*A* e *B*), frequentemente usado para normalização de cores.

Toda a base de dados foi convertida para esses esquemas, gerando novos conjuntos de dados sobre os quais serão extraídas características e realizadas as etapas de classificação. A Figura 3 mostra uma imagem de CEO em todos os esquemas de cores.

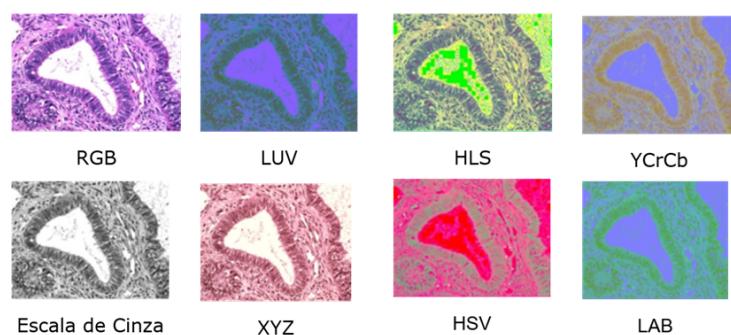


Figura 3. Imagem de CEO nas oito representações proposta.

3.3. Extração de Características Radiomics

Com os dados representados em diferentes esquemas de cores, as imagens passam pelo processo de análise utilizando a técnica de Radiomics. Essa técnica extrai características morfológicas, estatísticas e texturais, capturando padrões sutis não perceptíveis visualmente e correlacionando-os com aspectos clínicos e biológicos da doença, o que pode ter valor prognóstico [Neto et al. 2018, Park et al. 2020, Nardone et al. 2024]. Essa abordagem já foi aplicada a diferentes tipos de câncer, como pulmão e mama [Nardone et al. 2024], e, neste estudo, propõe-se, pela primeira vez, sua utilização na análise de imagens dessa neoplasia, avaliando sua eficácia na extração de características discriminantes para a classificação tumoral.

Embora as CNNs sejam amplamente utilizadas na análise de imagens médicas, o Radiomics oferece vantagens, como menor custo computacional e maior interpretabilidade, especialmente em cenários com dados limitados, como o câncer de ovário. Isso permite uma análise mais detalhada dos padrões e facilita a explicação dos resultados clínicos [Parekh and Jacobs 2019]. A extração das características foi realizada com a biblioteca PyRadiomics [Van Griethuysen et al. 2017], abrangendo as seguintes categorias e suas respectivas quantidades de características extraídas:

- **First Order (18)**: descrevem a distribuição dos pixels na imagem, sem considerar a relação entre eles.
- **Gray Level Co-occurrence Matrix (GLCM) (24)**: descrevem a relação entre pixels adjacentes na imagem.

- **Gray Level Dependence Matrix (GLDM) (14)**: descrevem a relação entre pixels em diferentes direções na imagem.
- **Gray Level Run Length Matrix (GLRLM) (16)**: descrevem a relação entre sequências de pixels com o mesmo valor na imagem.
- **Gray Level Size Zone Matrix (GLSZM) (16)**: descrevem a relação entre regiões da imagem com o mesmo valor.
- **Neighboring Gray Tone Difference Matrix (NGTDM) (5)**: descrevem a relação entre pixels adjacentes com tons semelhantes na imagem.

A técnica de Radiomics é normalmente aplicada em imagens em Escala de Cinza, compostas por um único canal. Este estudo amplia a abordagem para outros esquemas de cores, capturando padrões discriminantes em múltiplos canais e aproveitando a informação adicional para uma análise mais detalhada e robusta. Para a Escala de Cinza, foram extraídas 93 características, e para as imagens coloridas, 93 características por canal, totalizando 279 características por imagem.

3.3.1. Seleção de Características - Incremental RFE (I-RFE)

Devido ao número de características extraídas, tornou-se essencial aplicar técnicas de seleção para garantir que apenas as mais relevantes fossem utilizados na classificação do câncer de ovário. Para isso, empregou-se uma versão modificada do seletor RFE. O RFE é uma abordagem iterativa de eliminação de características, na qual um modelo preditivo é treinado e, a cada iteração, a característica menos relevante é removida, até atingir um número ideal de características [Guyon et al. 2002].

Neste estudo, em vez de remover uma característica por iteração, utilizou-se um critério baseado no F1-Score para determinar o ponto ideal de eliminação. Inicialmente, parte de um conjunto de C características extraídas. Em cada iteração, um subconjunto C^* reduzido das características era utilizado para treinar o modelo de classificação, e o F1-Score era calculado. Caso a remoção de características resultasse em uma melhora ou manutenção do desempenho, o processo continuava. Caso contrário, o algoritmo interrompia a eliminação, garantindo que apenas as características mais relevantes fossem mantidas para a etapa de classificação. O Algoritmo 1 descreve este processo.

Algorithm 1 Incremental RFE (I-RFE).

Require: D : Dados, C : Conjunto inicial, M : Modelo, F : Métrica (F1-Score)

Ensure: Conjunto otimizado C^*

```

1:  $C^* \leftarrow C$ ,  $F_{best} \leftarrow M(C^*)$ 
2: repeat
3:   Remover características irrelevantes de  $C^*$ , treinar  $M$  e calcular  $F_{new}$ 
4:   if  $F_{new} \geq F_{best}$  then
5:      $F_{best} \leftarrow F_{new}$ 
6:   else
7:     Interromper
8:   end if
9: until Sem melhoria
10: return  $C^*$ 

```

Com as melhores características selecionadas, o próximo passo é a classificação.

3.4. Classificação

Na etapa de classificação foi adotada a validação cruzada, uma vez que a base de dados é pequena e uma única divisão poderia gerar modelos enviesados. Em seguida, foram testados diversos algoritmos clássicos de aprendizado de máquina, frequentemente aplicados em tarefas de classificação [Carvalho et al. 2020, Diniz et al. 2024b]. Um breve resumo de cada algoritmo utilizado é apresentado a seguir.

- **Support Vector Machine (SVM)**: algoritmo de aprendizado supervisionado que busca encontrar o hiperplano ótimo para separar as classes no espaço de características, maximizando a margem entre os pontos de diferentes classes. Também é utilizado em tarefas de classificação binária devido à sua eficácia em conjuntos de dados complexos.
- **Random Forest (RF)**: algoritmo baseado em um conjunto de árvores de decisão. Cada árvore contribui com sua decisão, e a predição final é determinada por votação majoritária (para classificação) ou média (para regressão). Esse modelo melhora a generalização e reduz o risco de sobreajuste.
- **K-Nearest Neighbors (KNN)**: algoritmo de classificação baseado na proximidade dos exemplos no espaço de características. A classe de uma nova instância é determinada pela maioria dos seus k vizinhos mais próximos, tornando-o eficiente para problemas onde a distribuição espacial dos dados é um fator relevante.
- **XGBoost (XGB)**: baseado em *gradient boosting* que constrói múltiplas de árvores de decisão de forma sequencial, onde cada nova árvore corrige os erros das anteriores. Ele se destaca por sua eficiência computacional.
- **Adaptive Boosting (ADA)**: algoritmo de *ensemble learning* que combina múltiplos classificadores fracos, geralmente árvores de decisão simples, para formar um modelo mais robusto. O algoritmo atribui pesos maiores às amostras mal classificadas, ajustando os classificadores para focar nesses casos difíceis, resultando em uma melhoria da precisão do modelo.

Ao fim, todos os esquemas de cores são treinados para cada um dos classificadores, totalizando uma combinação de aproximadamente 40 experimentos.

3.5. Métricas de Validação

Para avaliar os resultados, foram utilizadas métricas de validação comuns para classificação. São elas: acurácia (ACC), especificidade (ESP), sensibilidade (SEN), precisão (PRE), F1-Score, Kappa e Área sob a curva ROC (AUC).

4. Resultados e Discussão

Para garantir uma avaliação completa do método proposto, foram conduzidos quatro experimentos, cada um correspondendo a uma etapa específica do método. No Experimento 1 são analisados os desempenhos utilizando as imagens originais em RGB. No Experimento 2 são destacados os melhores resultados obtidos para cada esquema de cor. O Experimento 3 avalia o impacto da inserção do RFE na seleção de características. Por fim, no Experimento 4, o método proposto é comparado com as principais CNNs da literatura, conforme descrito na Seção 2. Todos os experimentos foram conduzidos com validação

cruzada com k-fold = 5, e os classificadores utilizaram os hiperparâmetros padrão da biblioteca Scikit-Learn. Os resultados são apresentados em tabelas, com valores médios acompanhados do desvio padrão.

Os experimentos foram executados em um computador com as seguintes configurações: Intel® Core™ i5 @ 2.90GHz, Nvidia RTX-2060 6GB, 8GB de RAM e sistema operacional Windows 11 Pro. A implementação foi em Python, utilizando bibliotecas como Pandas, OpenCV, Scikit-Learn, SimpleITK, PyRadiomics e Keras.

4.1. Experimento 1 - Esquema de Cor Original (RGB) + Radiomics + Todos os Classificadores

É importante destacar que, nos três primeiros experimentos, o Radiomics foi empregado como técnica de extração de características. No primeiro experimento, as análises foram conduzidas utilizando apenas as imagens originais RGB, sem a aplicação do Incremental RFE. A Tabela 1 apresenta os resultados obtidos para todos os classificadores.

Tabela 1. Esquema de cor RGB + Radiomics + Todos os classificadores.

Esquema	Classificador	ACC	ESP	SEN	PRE	F1-Score	Kappa	AUC
RGB	SVM	$65,99 \pm 8,50$	$39,34 \pm 10,39$	$92,83 \pm 5,78$	$60,32 \pm 7,21$	$73,03 \pm 6,91$	$32,02 \pm 16,08$	$66,08 \pm 8,05$
RGB	KNN	$83,24 \pm 3,90$	$79,09 \pm 6,48$	$87,85 \pm 1,75$	$80,46 \pm 7,22$	$83,84 \pm 4,08$	$66,52 \pm 7,49$	$83,47 \pm 3,43$
RGB	RF	$96,96 \pm 3,28$	$96,59 \pm 5,20$	$96,92 \pm 4,41$	$97,33 \pm 3,84$	$97,06 \pm 3,10$	$93,84 \pm 6,60$	$96,76 \pm 3,37$
RGB	XGB	$94,88 \pm 3,64$	$93,69 \pm 4,67$	$95,69 \pm 4,84$	$94,10 \pm 3,92$	$94,84 \pm 3,83$	$89,62 \pm 7,40$	$94,69 \pm 3,77$
RGB	ADA	$95,92 \pm 2,91$	$94,59 \pm 5,48$	$96,82 \pm 2,93$	$95,38 \pm 4,62$	$96,03 \pm 2,80$	$91,76 \pm 5,84$	$95,71 \pm 2,93$

Os resultados indicam que a técnica de Radiomics apresentou um desempenho promissor, especialmente para os classificadores RF e ADA, que se destacaram com os melhores resultados. Utilizando o esquema de cor original e sem a seleção de características, ambos os classificadores alcançaram mais de 90% em praticamente todas as métricas avaliadas. O RF obteve o melhor desempenho, atingindo um F1-Score de 97,06%, evidenciando um excelente equilíbrio entre precisão e sensibilidade.

4.2. Experimento 2 - Todos os Esquemas de Cores + Radiomics + Melhor Classificador

A base de dados utilizada neste estudo é relativamente pequena, o que torna qualquer melhoria nas métricas um indicador promissor de ganhos potenciais em conjuntos de dados maiores. Portanto, foram realizados experimentos com todos os esquemas de cores e classificadores apresentados. Para fins de comparação, a Tabela 2 mostra apenas os resultados dos modelos com melhor desempenho.

Tabela 2. Esquemas de cores + Radiomics + Melhor classificador.

Esquema	Classificador	ACC	ESP	SEN	PRE	F1-Score	Kappa	AUC
RGB	RF	$96,96 \pm 3,28$	$96,59 \pm 5,20$	$96,92 \pm 4,41$	$97,33 \pm 3,84$	$97,06 \pm 3,10$	$93,84 \pm 6,60$	$96,76 \pm 3,37$
LUV	RF	$96,44 \pm 2,91$	$95,42 \pm 7,65$	$96,82 \pm 2,93$	$96,65 \pm 5,26$	$96,62 \pm 2,39$	$92,73 \pm 6,01$	$96,12 \pm 3,29$
Escala de Cinza	ADA	$96,96 \pm 2,12$	$95,59 \pm 4,85$	$97,99 \pm 2,75$	$96,38 \pm 3,59$	$97,12 \pm 1,88$	$93,85 \pm 4,32$	$96,79 \pm 2,32$
XYZ	RF	$96,42 \pm 2,93$	$93,51 \pm 6,60$	$98,82 \pm 2,63$	$94,51 \pm 4,30$	$96,57 \pm 2,67$	$92,69 \pm 6,08$	$96,17 \pm 3,34$
HLS	RF	$95,45 \pm 2,07$	$94,91 \pm 0,52$	$95,89 \pm 4,38$	$94,90 \pm 0,53$	$95,36 \pm 2,32$	$90,84 \pm 4,13$	$95,40 \pm 2,11$
YCrCb	RF	$97,45 \pm 1,81$	$96,59 \pm 5,19$	$97,77 \pm 3,06$	$97,42 \pm 3,77$	$97,52 \pm 1,58$	$94,80 \pm 3,74$	$97,18 \pm 2,08$
HSV	ADA	$92,90 \pm 3,31$	$92,00 \pm 4,26$	$93,74 \pm 6,60$	$91,94 \pm 4,31$	$92,69 \pm 3,76$	$85,71 \pm 6,63$	$92,86 \pm 3,16$
LAB	ADA	$94,92 \pm 1,81$	$92,60 \pm 6,65$	$96,82 \pm 2,93$	$93,57 \pm 4,61$	$95,05 \pm 1,41$	$89,69 \pm 4,38$	$94,71 \pm 2,23$

Mais uma vez, a técnica de Radiomics provou ser altamente eficaz, alcançando desempenhos consistentes em todos os esquemas de cores avaliados. Vale ressaltar que os

classificadores RF e ADA obtiveram as melhores médias associadas aos desvios padrão, o que pode ser atribuído à sua capacidade de capturar padrões complexos nas características extraídas das imagens [Carvalho et al. 2020].

Além disso, os esquemas de cores Escala de Cinza e YCrCb destacaram-se como os mais eficazes. A Escala de Cinza, ao eliminar informações cromáticas e enfatizar as variações de intensidade, favorece a extração de texturas e contrastes, que podem ser relevantes na diferenciação de padrões patológicos. Já o esquema YCrCb, ao separar a luminância (Y) das componentes cromáticas (Cr e Cb), permite que os classificadores se concentrem melhor nas informações estruturais presentes na luminância, que geralmente contém os detalhes mais relevantes em imagens médicas.

4.3. Experimento 3 - Todos os Esquemas de Cores + Radiomics + I-RFE

Por fim, foi feito uma comparação entre todos os esquemas de cores, juntamente com o I-RFE. Os resultados obtidos estão descritos na Tabela 3, com o número de características selecionadas indicadas entre parênteses na segunda coluna.

Tabela 3. Esquemas de cores + Radiomics + I-RFE + Melhor classificador.

Esquema	Classificador	ACC	ESP	SEN	PRE	F1-Score	Kappa	AUC
RGB	RF + I-RFE (259)	96,45 ± 2,85	95,59 ± 4,85	96,92 ± 4,41	96,33 ± 3,61	96,55 ± 3,61	92,81 ± 5,75	96,26 ± 2,92
LUV	RF + I-RFE (249)	96,96 ± 2,12	95,64 ± 4,84	97,99 ± 2,75	96,38 ± 3,59	97,12 ± 1,88	93,85 ± 4,32	96,82 ± 2,33
Escala de Cinza	ADA + I-RFE (66)	97,96 ± 1,14	96,77 ± 2,97	98,82 ± 2,63	97,22 ± 2,55	97,97 ± 1,18	95,87 ± 2,31	97,79 ± 1,25
XYZ	RF + I-RFE (168)	96,94 ± 2,81	93,51 ± 6,59	99,89 ± 0,15	94,58 ± 4,29	97,17 ± 4,29	93,74 ± 5,85	96,75 ± 3,29
HLS	RF + I-RFE (259)	96,46 ± 1,33	94,91 ± 0,52	97,99 ± 2,75	95,01 ± 0,46	96,47 ± 1,38	92,88 ± 2,65	96,45 ± 1,36
YCrCb	RF + I-RFE (166)	97,96 ± 1,14	95,42 ± 4,18	99,89 ± 0,15	96,69 ± 3,26	98,26 ± 2,63	96,80 ± 2,61	97,71 ± 2,89
HSV	ADA + I-RFE (259)	92,90 ± 3,31	92,00 ± 4,26	93,74 ± 6,60	91,94 ± 4,31	92,69 ± 3,78	85,72 ± 6,63	92,87 ± 3,16
LAB	ADA + I-RFE (259)	94,92 ± 1,81	92,60 ± 6,65	96,82 ± 2,93	93,57 ± 4,61	95,05 ± 1,41	89,69 ± 3,84	94,71 ± 2,23

Os resultados obtidos destacam a importância do I-RFE na seleção de características, refletindo positivamente nas métricas finais. Destacado na Seção 3.3, foram extraídas 279 características, e ao comparar com os resultados da Tabela 3, nota-se que a aplicação do I-RFE resultou em uma redução no número de características, mantendo as mais relevantes para o diagnóstico de CEO. Portanto, a análise das métricas revela que o I-RFE contribuiu para um aprimoramento dos resultados.

A análise das métricas indica que os esquemas de cores escala de cinza e YCrCb tiveram os melhores desempenhos. A escala de cinza, com um único canal, resultou na extração de 93 características, reduzindo 27 atributos. O YCrCb apresentou uma redução ainda maior, eliminando 103 características, mantendo alto desempenho com acurácia de 97,96%. Além disso, seu F1-Score de 98,26% reflete um equilíbrio robusto entre sensibilidade e precisão, enquanto o Kappa de 96,80% indica alta concordância com os rótulos reais, superando os resultados da escala de cinza. Assim, o YCrCb se destaca como o esquema de cor mais adequado, garantindo uma extração eficiente sem comprometer a robustez do modelo.

Ainda, houve a redução do desvio padrão, indicando maior estabilidade e consistência nos resultados. Isto sugere que o modelo se tornou mais robusto e menos sensível a variações nos dados que essencial para garantir confiabilidade em contextos médicas.

4.4. Experimento 4 - Comparação do Melhor Resultado vs Aprendizado Profundo

Como nenhum dos trabalhos relacionados na Seção 2 realizou diretamente a classificação do CEO e NC, optou-se por comparar o desempenho do método proposto com as CNNs

mais comumente utilizadas nesses estudos. Portanto, este experimento busca aproximar a comparação do método proposto com os apresentados na literatura.

As imagens originais foram utilizadas como entrada e processadas por diferentes CNNs. Três arquiteturas conhecidas (VGG-16, ResNet-50 e InceptionV3) foram selecionadas com pesos pré-treinados no ImageNet. O treino foi realizado utilizando o otimizador Adam com seus hiperparâmetros padrão, com entropia cruzada como função de perda e 30 épocas. Além disso, foi adotado um esquema de validação hold-out com divisão 80/20, uma vez que a validação cruzada implicaria custos computacionais e tempo de execução excessivamente elevados. Os resultados obtidos são ilustrados na Figura 4.

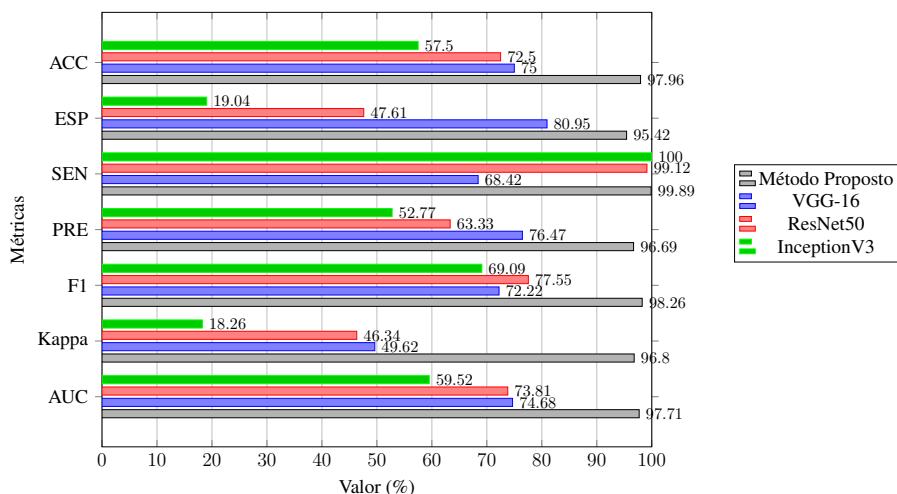


Figura 4. Comparação das métricas dos modelos de CNN e do método proposto.

O método proposto superou as CNNs testadas. Vale destacar que a InceptionV3 apresentou sobreajuste (*overfitting*), aprendendo uma única classe, provavelmente devido à limitação na quantidade de imagens disponíveis para treinamento. Mesmo com o melhor resultado obtido pela VGG-16, o método proposto obteve uma vantagem superior a 15% em todas as métricas. Isso evidencia que a combinação das técnicas propostas é capaz de classificar corretamente o CEO, mesmo em bases de dados pequenas, com um custo computacional significativamente menor em comparação com o uso de CNNs.

Os resultados demonstram que o método proposto pode melhorar a acurácia na detecção de CEO em imagens histopatológicas. Essa abordagem tem potencial para ser integrada em sistemas de auxílio ao diagnóstico (CADx), fornecendo suporte valioso aos patologistas na identificação de padrões sutis e na diferenciação entre tecidos canerígenos e NC.

5. Conclusão

Neste trabalho foram explorados oito esquemas de cores distintos para aprimorar as imagens histopatológicas, permitindo uma análise mais detalhada das características do CEO. Adicionalmente, foi proposta a utilização da técnica de Radiomics otimizada pela seleção de características por meio do I-RFE, representando a primeira aplicação dessa abordagem para a classificação de imagens de COE.

Além disso, os testes foram realizados com diversos classificadores, ampliando a aplicabilidade do método para diferentes cenários. A combinação dessas técnicas resultou em métricas expressivas, com destaque para a acurácia de 97,96% e F1-Score de 98,26% obtidos com o esquema de cor YCrCb.

Como trabalhos futuros, sugere-se expandir a abordagem para multiclasse, abrangendo os diferentes subtipos de câncer de ovário. Além disso, pretende-se validar o método em outras bases de dados com mais amostras. Por fim, acredita-se que seja possível aprimorar ainda mais os resultados por meio da otimização de hiperparâmetros.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, Fundação de Amparo a Pesquisa do Maranhão (FAPEMA), 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

- 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.
- Chaturvedi, M., Krishnan, S., Das, P., Sudarshan, K., Stephen, S., Monesh, V., and Mathur, P. (2023). Descriptive epidemiology of ovarian cancers in india: A report from national cancer registry programme. *Indian Journal of Gynecologic Oncology*, 21(1):25.
- Diniz, J., Jr, D. D., Cruz, L., Marques, R., Jr, D. G., Cortês, O., Filho, A. C., and Quintanilha, D. (2024a). Efficientensemble: Diagnóstico de câncer de mama em imagens de ultrassom utilizando processamento de imagens e ensemble de efficientnets. In *Anais do XXIV Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 202–213, Porto Alegre, RS, Brasil. SBC.
- Diniz, J., Quintanilha, D., Filho, A. C., Jr, D. G., Silva, A., Jr, G. B., Paiva, A., and Luz, D. (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, Porto Alegre, RS, Brasil. SBC.
- Diniz, J., Ribeiro, N., Junior, D. D., Cruz, L., Filho, A. C., Jr, D. G., Silva, A., and Paiva, A. (2024b). Efficientxyz-deepfeatures: Seleção de esquema de cor e arquitetura deep features na classificação de câncer de cólon em imagens histopatológicas. In *Anais do XXIV Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 82–93, Porto Alegre, RS, Brasil. SBC.
- Gonzalez, R. and Woods, R. (2008). *Digital image processing*. Pearson, Prentice Hall.
- Gonçalves, J., Souza, D., Santos, C., Nascimento, C., Cruz, L., Junior, D. D., and Diniz, J. (2024). D.iagnóstica: 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.

- Guyon, I., Weston, J., Barnhill, S., and Vapnik, V. (2002). Gene selection for cancer classification using support vector machines. *Machine learning*, 46:389–422.
- Ifty, M. H. S., Nirjan, N., Islam, L., Diganta, M., Ornate, R. A., Tasnim, A., and Islam, M. S. (2025). Automated detection of malignant lesions in the ovary using deep learning models and xai. In *2025 IEEE 4th International Conference on AI in Cybersecurity (ICAIC)*, pages 1–8. IEEE.
- Kasture, K. (2021). Ovarian cancer & subtypes dataset histopathology. *Mendeley Data*.
- Lakshmanan, S., Nagaraja, P., Rani, M. M. S., and Shanmugavadi, P. (2023). Deep convolutional neural network for the prediction of ovarian cancer. In *Combating Women's Health Issues with Machine Learning*, pages 107–119. CRC Press.
- Leyland, N., Casper, R., Laberge, P., Singh, S. S., Allen, L., Arendas, K., Leyland, N., Allaire, C., Awadalla, A., Best, C., et al. (2010). Endometriosis: diagnosis and management. *Journal of Endometriosis*, 2(3):107–134.
- Nardone, V., Reginelli, A., Rubini, D., Gagliardi, F., Del Tufo, S., Belfiore, M. P., Boldrini, L., Desideri, I., and Cappabianca, S. (2024). Delta radiomics: an updated systematic review. *La radiologia medica*, 129(8):1197–1214.
- Neto, A. C. d. S., Diniz, P. H., Diniz, J. O., Cavalcante, A. B., Silva, A. C., de Paiva, A. C., and de Almeida, J. D. (2018). Diagnosis of non-small cell lung cancer using phylogenetic diversity in radiomics context. In *Image Analysis and Recognition: 15th International Conference, ICIAR 2018, Póvoa de Varzim, Portugal, June 27–29, 2018, Proceedings 15*, pages 598–604. Springer.
- Parekh, V. S. and Jacobs, M. A. (2019). Deep learning and radiomics in precision medicine. *Expert review of precision medicine and drug development*, 4(2):59–72.
- Park, J. E., Kim, H. S., Kim, D., Park, S. Y., Kim, J. Y., Cho, S. J., and Kim, J. H. (2020). A systematic review reporting quality of radiomics research in neuro-oncology: toward clinical utility and quality improvement using high-dimensional imaging features. *BMC cancer*, 20:1–11.
- Pavithra, S., Kumar, L. A., and Phaniraj, H. (2024). Deep learning perspective for preliminary detection and classification of ovarian cancer. In *2024 IEEE 9th International Conference for Convergence in Technology (I2CT)*, pages 1–7. IEEE.
- Radhakrishnan, M., Sampathila, N., Muralikrishna, H., and Swathi, K. (2024). Advancing ovarian cancer diagnosis through deep learning and explainable ai: A multiclassification approach. *IEEE Access*.
- Reid, B. M., Permuth, J. B., and Sellers, T. A. (2017). Epidemiology of ovarian cancer: a review. *Cancer biology & medicine*, 14(1):9.
- Van Griethuysen, J. J., Fedorov, A., Parmar, C., Hosny, A., Aucoin, N., Narayan, V., Beets-Tan, R. G., Fillion-Robin, J.-C., Pieper, S., and Aerts, H. J. (2017). Computational radiomics system to decode the radiographic phenotype. *Cancer research*, 77(21):e104–e107.
- Wong, R. W., Ip, P. P., and Cheung, A. N. (2024). Mucinous tumours of the ovary. In *Pathology of the Ovary, Fallopian Tube and Peritoneum*, pages 417–438. Springer.