

# Classification of Lung Cancer in Medical Imaging Using Convolutional Networks with CLAHE Preprocessing and Wavelet Transform

Moisés José M. Ribeiro, Pedro Moises de Sousa

\*Instituto de Ciências Exatas e Tecnológicas, Universidade Federal de Viçosa - Campus Rio Paranaíba (UFV-CRP)  
Rodovia MG230, Km7, Caixa Postal 22, 38.810-000, Rio Paranaíba, MG, Brasil  
Emails: {moises.ribeiro, pedromoises}@ufv.br

**Abstract**—Convolutional neural networks (CNNs) play a crucial role in the early detection of diagnoses, assisting healthcare professionals in decision-making. This study uses different CNNs (AlexNet, ResNet-50, and EfficientNet) to classify computed tomography (CT) scan images for lung cancer detection, using the IQ-QTH/NCC and LIDC-IDRI datasets. The models were trained and evaluated with various magnifications and epochs, measuring the performance of each model based on metrics such as accuracy, precision, and recall. The results showed that ResNet-50 achieved an average accuracy of 96.12%. AlexNet reached 94.38%, and EfficientNet obtained 94.38%.

**Index Terms** - Lung Cancer, Lung, Convolutional Neural Network, Wavelet, Clahe

## I. INTRODUÇÃO

Na América Latina, nos últimos anos, o câncer de pulmão emergiu com uma alta taxa de mortalidade [1]. A falta de infraestrutura médica, profissionais de saúde e acesso aos sistemas de saúde tem agravado o avanço do câncer na maioria dos países [1]. A situação é ainda pior para pessoas em situação de pobreza, considerando a crise econômica que atravessa a América Latina, especialmente para aquelas com menos recursos econômicos.

No Brasil, a realidade não é diferente, o câncer de pulmão apresenta alta taxa de mortalidade [2]. Da mesma forma, muitas pessoas não tem acesso aos serviços médicos devido a falta de infraestrutura [3]. Segundo o Instituto Nacional de Câncer (INCA), o câncer de pulmão, em 2023, é o terceiro mais comum em homens (18.020 novos casos) e o quarto em mulheres (14.540 novos casos). Em mortalidade, é o primeiro entre homens e o terceiro entre as mulheres [2].

A descoberta do câncer de pulmão em estágio inicial é o único método para sua cura. Diferentes métodos estão disponíveis para diagnóstico do câncer de pulmão, a saber, ressonância magnética (RM), raios-X e tomografia computadorizada (TC). A radiografia de tórax por raios-X e a tomografia computadorizada são as duas modalidades de imagem anatômica familiares que são regularmente utilizadas no reconhecimento de diferentes doenças pulmonares.

Sendo assim, a detecção precoce do câncer de pulmão é crucial para permitir tratamentos mais eficazes, aumentando

as chances de cura e reduzindo os associados. Redes neurais convolucionais (CNNs) são particularmente eficazes na identificação de padrões complexos em imagens médicas, auxiliando médicos e radiologistas a tomar decisões mais rápidas e precisas. Estudos, como o de [4], demonstram que técnicas de *deep learning* não apenas reduzem o tempo de diagnóstico, mas também identificam casos que ser inicialmente negligenciado por especialistas. Assim, a aplicação de inteligência artificial, através de CNNs, representa um avanço significativo na medicina, destacando-se como um campo importante na saúde pública devido ao potencial de salvar vidas e diminuir custos.

Nesse contexto, o objetivo deste estudo foi avaliar o desempenho de três modelos diferentes de redes neurais convolucionais aplicadas no diagnóstico de câncer de pulmão por meio de imagens médicas. Utilizando conjuntos de dados de tomografias computadorizadas de pulmões classificadas em dois estados, maligno e normal. Esses três modelos são: *ResNet50*, *AlexNet* e *EfficientNet*. Os critérios para seleção foram três, representatividade, desempenho e disponibilidade.

## II. REFERENCIAL TEÓRICO

### A. Câncer de Pulmão

De acordo com a Comissão Nacional de Incorporação de Tecnologias no Sistema Único de Saúde (Conitec), o câncer de pulmão faz parte de um grupo de carcinomas que surge a partir da multiplicação desordenada de células anormais que revestem a parte inferior da traqueia, os brônquios, bronquíolos, alvéolos e os pulmões [5].

Os tumores benignos, por outro lado, geralmente apresentam um crescimento lento, não se espalham para outras regiões do corpo e não invadem os tecidos ao redor. Esses tumores tendem a não causar sintomas, a menos que cresçam a ponto de pressionar outras estruturas [6].

Por outro lado, os tumores malignos (câncer) possuem um crescimento rápido e descontrolado. Eles podem se expandir e invadir áreas próximas, além de suas células se desprenderem e se espalharem pelo sistema linfático ou circulatório, podendo iniciar o crescimento de novos tumores em outras partes do corpo. Esse processo é conhecido como metástase [6].

## B. Redes Neurais Convolucionais (CNNs)

As Redes Neurais Convolucionais (CNNs) são uma arquitetura específica de redes neurais projetadas para analisar padrões espaciais, como aqueles encontrados em imagens [7]. Esse tipo de rede faz uso de uma operação matemática chamada de convolução, cuja principal função é extrair características importantes de uma imagem, como cores, bordas e textura [8]. Uma rede neural convolucional é composta por diversos componentes, cada um com funções específicas, conforme ilustrado na Figura 1.

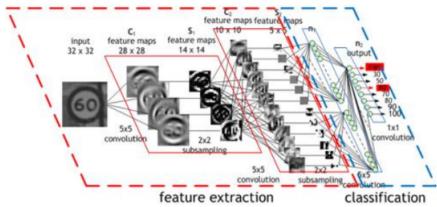


Fig. 1: Exemplo de uma rede neural convolucional e suas diferentes camadas [9].

A estrutura de uma Rede Neural Convolucional (CNN) é composta por diferentes camadas, cada uma com uma função específica na análise e extração de características de uma imagem. Diversos autores, como [19], descrevem uma divisão padrão das camadas em uma CNN, que tipicamente incluem:

1) *Camadas Convolucionais*: A camada convolucional é um componente principal da arquitetura de Redes Neurais Convolucionais (CNNs). Nessas camadas, um conjunto de filtros é aplicado nas imagens de treinamento a fim de extraír suas características, como cores, bordas ou texturas. A saída gerada após esse processo de convolução consiste em um mapa, denominado "mapa de características" que indica toda as localizações dentro da imagem onde foi detectada a característica visual relevante [10].

2) *Camadas de não Linearidade*: São utilizadas para aprender características mais sofisticadas da entrada e adicionar complexidade ou profundidade à rede. A maioria dos dados do mundo real não são lineares e não podem ser treinados apenas com funções lineares [8].

O *pooling* reduz o tamanho espacial da representação, com o objetivo de agrupar ou extraír as características mais importantes da saída de uma amada convolucional [8]. O esquema desse processo é representado na Figura 2.

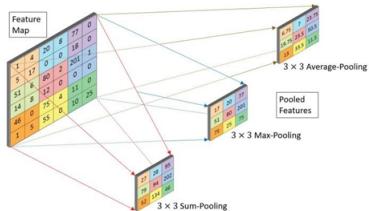


Fig. 2: Exemplo de uma rede neural convolucional e suas diferentes camadas [9].

3) *Camadas totalmente conectadas*: Após a convolução, as camadas totalmente conectadas, são semelhantes à rede neural artificial e contêm neurônios que estão conectados aos neurônios da camada anterior. Nesta etapa, as características espaciais são empregadas para calcular as probabilidades para cada classe, indicando o quanto bem uma característica específica se encaixa em cada uma das possíveis categorias [11].

## III. TRABALHOS RELACIONADOS

Recentemente, vários estudos têm se dedicado à avaliação do diagnóstico precoce do câncer de pulmão utilizando Redes Neurais Convolucionais (CNNs).

No estudo [17], foi realizado um treinamento utilizando a rede neural convolucional AlexNet, aplicada à classificação de imagens de tomografia computadorizada de câncer de pulmão. A Pesquisa utilizou o conjunto de dados IQ-OTH/NCC [12], que contém imagens de tumores malignos e imagens saudáveis. O desempenho do modelo foi avaliado com base em métricas como, AUC, sensibilidade, especificidade, *recall* e F1-Score. Todas as imagens foram redimensionadas para 224 x 224 pixels. O treinamento foi realizado por 100 épocas, com uma taxa de aprendizado inicial de 0,001 e o uso de estratégias de aumento de dados para prever overfitting. No processo e treinamento, o conjunto de dados é dividido em 2 grupos, 70% para fase de treinamento e 30% para fase de teste. Os resultados mostram que a arquitetura AlexNet apresenta uma acurácia, de 93,54% ao ser aplicado no conjunto de dados coletados, além de oferecer uma precisão de até 97,10%, sensibilidade de 95,71% e uma especificidade que atinge aproximadamente 95%.

A pesquisa de Narin e Onur (2022) [18] comparou os desempenhos dos modelos AlexNet e ResNet-50 na extração de características e na classificação de imagens usando Máquinas de Vetores de Suporte (SVM), empregando 70% do conjunto de dados para treinamento e 30% para teste. O AlexNet alcançou uma acurácia máxima de 98,58% com um tamanho de lote de 64 e 200 épocas, mas apresentou uma tendência de queda no desempenho com o aumento das épocas. Em contraste, o ResNet-50 obteve uma acurácia de 97,97% com as mesmas configurações e se destacou com um Recall de 100% na detecção de imagens malignas e uma acurácia geral de 99,39% nessa classe. Ambas as redes neurais foram treinadas com imagens do Dataset IQ-OTH/NCC [12].

O estudo [20] foi explorado o uso da arquitetura EfficientNet com filtros e núcleos de *pooling* 3D. O desempenho da classificação proposta de nódulos foi avaliado no conjunto de dados público LUNA16, um subconjunto do Lung Database Consortium e Image Database Resource (LIDC-IDRI). Foram usados nódulos com diâmetro maior que 3mm, totalizando 793 nódulos (437 benignos e 356 malignos) para treinamento e teste. A classificação dos nódulos foi baseada em score de malignidade, com nódulos em score maior que três sendo malignos. Imagens 3D de 48 x 48 x 48 ao redor do centro do nódulo foram extraídas e normalizadas. A EfficientNet foi treinada por 200 épocas com uma taxa de aprendizado inicial de 0,001, alcançando uma acurácia de 92,5%. O método

proposto fornece um módulo independente com previsão encorajadora.

#### IV. METODOLOGIA

Neste capítulo, será apresentada a metodologia empregada neste estudo, que utiliza dados dos *DataSets* IQ-QTH/NCC[12] e LIDC-IDRI[13]. O objetivo do estudo é aplicar três Redes Neurais Convolucionais (CNNs) distintas, a saber, AlexNet, ResNet-50 e EfficientNet, utilizando como ferramenta a biblioteca *PyTorch* para implementação e execução dessas redes. A metodologia será conduzida conforme o fluxo representado no diagrama geral ilustrado na Figura 3.

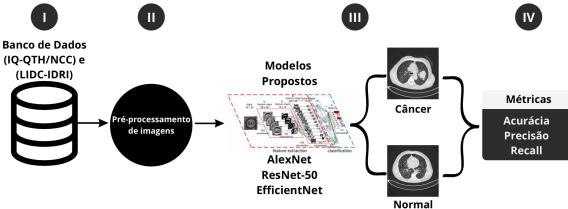


Fig. 3: Diagrama Geral da Metodologia

##### A. Base de Dados

1) *IQ-QTH/NCC*: O *dataset* IQ-QTH/NCC [12], contém imagens do Banco de Imagens Médicas do Hospital Universitário de Oncologia do Iraque/Centro Nacional de doenças do Câncer. As imagens foram coletadas ao longo do ano de 2019 durante três meses. O Conjunto de dados inclui 1097 imagens de 512 x 512 pixels, representando cortes de tomografia computadorizada de 110 casos. Esses casos são agrupados em duas classes: normal e maligno. Destes, 55 casos são diagnosticados como malignos e 55 casos diagnosticados como normal. O scanner utilizado é da marca Siemens, modelo SOMATOM. Os 110 casos variam em sexo, idade, escolaridade, área de residência e status de vida. Alguns deles são funcionários públicos, criadores de gado e agricultores.

2) *LIDC-IDRI*: O conjunto de dados proveniente da coleção de imagens do Lung Image Database Consortium (LIDC-IDRI [13]) consiste em exames de tomografia computadorizada (TC). O conjunto de dados contém 1018 casos, cada um dos quais inclui imagens de uma tomografia computadorizada clínica de tórax e um arquivo XML associado que registra os resultados de um processo de anotação de imagem em duas fases realizado por quatro radiologistas torácicos experientes. O conjunto de dados contém 7371 lesões marcadas como "nódulos" por pelo menos um radiologista. Destas, 2669 foram marcadas como "nódulo > ou = 3mm" por pelo menos um radiologista, das quais 928 (34,7%) receberam tais marcas dos quatro radiologistas. Essas 2669 lesões incluem contornos de nódulos e classificações subjetivas de características de nódulos.

##### B. Pré-Processamento

Seguindo o que está indicado na Figura 3 (II), será aplicado pré-processamento nos conjuntos de dados, incluindo critérios

de inclusão e exclusão de imagens para o treinamento dos modelos.

O primeiro passo foi definir esses critérios para as bases de dados IQ-QTH/NCC [12] e LIDC-IDRI [13]. Os critérios de inclusão foram: i) disponibilidade dos dados publicamente, ii) imagens médicas tomográficas com resolução 512 x 512 pixels, iii) imagens de pacientes com câncer de pulmão, iv) imagens de pulmão saudável.

Os critérios de exclusão foram aplicados para descartar cerca de 50% das imagens de cada exame. Isso corresponde a 25% das fatias iniciais e 25% das fatias finais de cada exame, ajudando a focar a análise de áreas mais relevantes. A Figura 5 representa como foi realizado esse critério de exclusão.

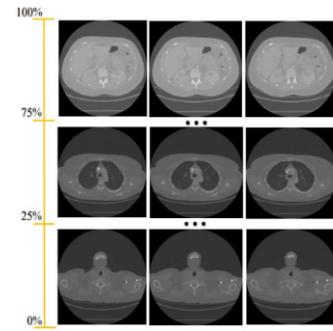


Fig. 4: Critério de exclusão

Posteriormente, foi aplicado às imagens filtros a fim de obter uma melhor classificação. Para o estudo, foram utilizados dois filtros:

1) *Wavelet*: O filtro de imagem Wavelet foi utilizado para decompor as imagens em sinais de diferentes escalas, facilitando a remoção de ruídos, a compreensão da imagem e a alteração de sua resolução [15]. A família da Wavelet utilizada no conjunto de dados foi a "coif5".

2) *Clahe*: O filtro do Clahe (Equalização de Histograma Adaptativa com Limitação de Contraste) é uma variação do AHE (Equalização de Histograma Adaptativa). O aumento de contraste é realizado na vizinhança de um pixel e ajustado pelo declive da função de transformação [14]. O Clahe atua em pequenas regiões da imagem, aplicando a técnica dentro de cada bloco. O limite de contraste aplicado no estudo é de 0,02 [14]. A Figura 6 exemplifica como foi a aplicação desses filtros.

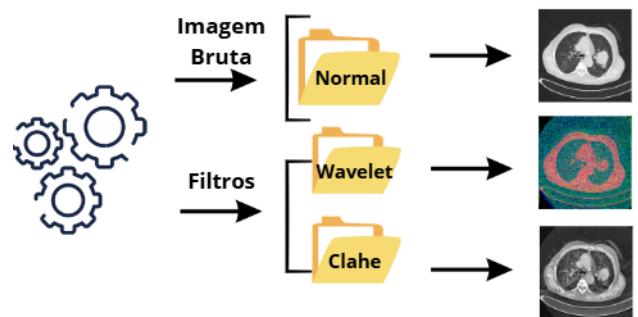


Fig. 5: Filtros aplicados

### C. Coleta e Preparação dos Dados

Conforme ilustrado na Figura 3 (I), esta etapa abrange a coleta e organização dos dados proveniente das bases IQ-QTH/NCC [12] e LIDC-IDRI [13], fundamentais para o treinamento e validação das Redes Neurais Convolucionais (CNNs). Inicialmente, as imagens foram coletadas e organizadas de maneira cuidadosa em duas categorias distintas: Câncer Maligno e Imagens Normais. Posteriormente, foi realizada uma pré-distribuição das imagens, assegurando uma quantidade igual de amostras para ambas as categorias. Assim, garantiu-se uma distribuição balanceada de imagens para cada categoria (câncer e normal).

Após a etapa de organização e pré-distribuição, os dados foram separados para compor os conjuntos de treinamento, validação e teste, com 70% do total de imagens alocado para o treinamento, 15% para validação e 15% para teste. A Figura 4 apresenta um exemplo de como a base de dados foi dividida.

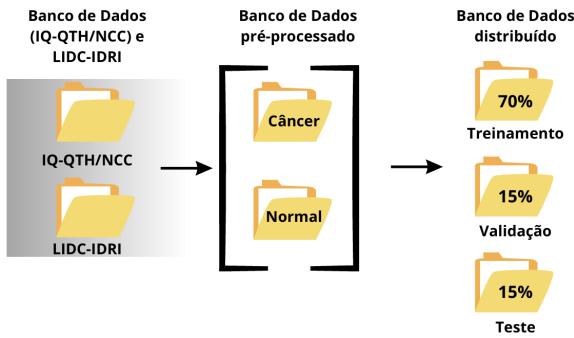


Fig. 6: Exemplificação da preparação dos dados

### D. Treinamento e Avaliação das Redes Neurais Convolucionais

Nesta etapa, conforme ilustrado na Figura 3 (III), serão implementadas três Redes Neurais Convolucionais (CNNs) distintas: AlexNet, ResNet-50 e EfficientNet, utilizando a biblioteca PyTorch. Cada CNN será treinada e avaliada com foco na capacidade do modelo de classificar as imagens como tumor maligno ou normal.

Para execução dos treinamentos, foi utilizado um computador com as seguintes especificações técnicas: uma GPU Nvidia GeForce RTX 3050 Ti com 6GB de memória dedicada, um processador Intel Core i5-13450HX e 16GB de memória DDR5. Foram definidos parâmetros básicos no código, como o tamanho do lote (*bath size*) de 32, uma *SEED* de 42, uma taxa de aprendizado (*learning rate*) de 0,0001. A função de perda utilizada foi "CrossEntropyLoss", e o otimizador escolhido foi o ADAM da biblioteca PyTorch. O treinamento foi realizado ao longo de 100 épocas. Observou-se que, após 100 épocas, a acurácia do modelo estabilizou e não apresentou melhorias adicionais, indicando que o treinamento atingiu um ponto de saturação em termos de desempenho. O otimizador escolhido para o estudo foi o ADAM da biblioteca PyTorch.

Ao longo do projeto, foram realizados diversos testes para ajustar o tamanho do lote e a taxa de aprendizado até que

se encontrassem os valores mais apropriados para alcançar o melhor desempenho. Esses parâmetros foram aplicados de forma consistente em todos os modelos durante o treinamento e a validação, assegurando a comparação justa dos resultados obtidos.

### E. Avaliação dos Modelos

Como apresentado na Figura 3 (IV), durante a avaliação dos modelos de detecção de câncer de pulmão, utilizou-se o conjunto de teste para prever as etiquetas das classes, gerando métricas como acurácia, precisão e recall, além da curva ROC e matriz de confusão.

A acurácia reflete a proporção de previsões corretas, enquanto a precisão mede a taxa de verdadeiros positivos (VP) entre as previsões positivas. O recall avalia a proporção de VPs identificados em relação ao total de positivos [16]. A curva ROC, que relaciona a taxa de verdadeiros positivos e falsos positivos, tem sua performance quantificada pela AUC (Área Sob a Curva). A matriz de confusão detalha o desempenho do modelo para cada classe, ajudando a identificar erros de classificação, como falsos positivos (FP) e falsos negativos (FN), essenciais para diagnósticos precisos e minimizar erros em detecção de câncer [16].

$$\text{Acurácia (ACC)} = \frac{VP + VN}{VP + VN + FP + FN} \quad (1)$$

$$\text{Precisão (PRE)} = \frac{VP}{VP + FP} \quad (2)$$

$$\text{Recall (REC)} = \frac{VP}{VP + FN} \quad (3)$$

## V. RESULTADOS E DISCUSSÃO

Nesse tópico, será apresentado uma análise geral do desempenho de cada um dos modelos AlexNet, ResNet-50 e EfficientNet.

1) *Conjunto de dados I*: Foi realizado um teste em 100 épocas no *dataset* (IQ-QTH/NCC) [12], a Tabela I apresenta os resultados. Nota-se que o modelo ResNet-50 apresentou maior valor de acurácia na classificação dos dados brutos, alcançando, respectivamente 94,44% de acurácia. O modelo AlexNet apresentou boa classificação nos dados com o filtro de Clahe aplicado, apresentando uma acurácia de 96,82% superando as demais redes neurais. Com o filtro de Wavelet aplicado, a rede ResNet-50 obteve o melhor resultado, com uma acurácia de 80,74%.

2) *Conjunto de dados II*: Para o conjunto de dados LIDC-IDRI [13] foi realizado um teste em 100 épocas. A Tabela II apresenta os resultados desse treinamento. O Modelo ResNet-50 apresenta maior valor de acurácia na classificação dos dados brutos, alcançando 97,80%. Todos os modelos apresentaram valor de Precisão igual a 100% garantindo que todas as previsões feitas como "positivas" foram corretas. O modelo EfficientNet utilizando os filtros de Wavelet e Clahe apresentou melhores resultados que os demais modelos. Com o filtro de Wavelet a rede apresentou uma acurácia de 95,40% e com o filtro de Clahe uma acurácia de 97,30%.

TABELA I: RESULTADO DAS MÉTRICAS DE AVALIAÇÃO EM 100 ÉPOCAS

Arquitetura	Filtro Aplicado	ACC (%)	PRE (%)	REC (%)
AlexNet	Bruto	93,85%	95%	90%
	Wavelet	66,66%	62%	87%
	Clahe	<b>96,82%</b>	98%	95%
ResNet-50	Bruto	<b>94,44%</b>	92%	97%
	Wavelet	<b>80,74%</b>	85%	74%
	Clahe	92,85%	98%	87%
EfficientNet	Bruto	93,36%	88%	89%
	Wavelet	73,01%	76%	67%
	Clahe	84,92%	91%	78%

TABELA II: RESULTADO DAS MÉTRICAS DE AVALIAÇÃO EM 100 ÉPOCAS

Arquitetura	Filtro Aplicado	ACC (%)	PRE (%)	REC (%)
AlexNet	Bruto	94,90%	100%	89%
	Wavelet	90,20%	100%	81%
	Clahe	90,50%	100%	81%
ResNet-50	Bruto	<b>97,80%</b>	100%	97%
	Wavelet	95%	100%	90%
	Clahe	90,80%	100%	82%
EfficientNet	Bruto	95,40%	100%	81%
	Wavelet	<b>95,40%</b>	100%	91%
	Clahe	<b>97,30%</b>	100%	95%

A Figura 7 apresenta uma comparação gráfica da média das acuráncias obtidas pelos três modelos em relação aos dois conjuntos de dados utilizados no estudo.

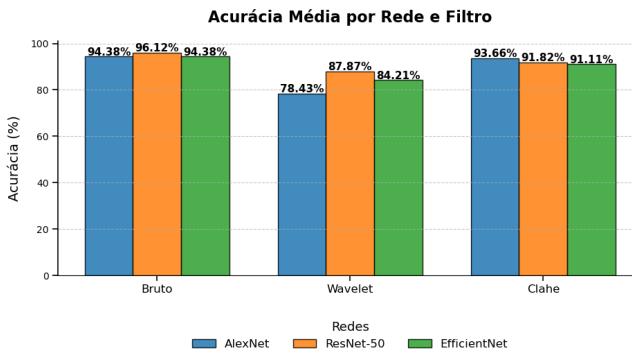


Fig. 7: Média gráfica das acuráncias obtidas

Os resultados obtidos com os métodos propostos representam as médias de desempenho dos dois conjuntos de dados I e II, mostrando um desempenho competitivo em relação aos modelos descritos em outros estudos, conforme ilustrado na Tabela III. Embora nossos modelos não tenham superado todos os parâmetros de referência apresentados, eles alcançaram resultados relevantes. Por exemplo, o modelo AlexNet obteve uma acurácia de 94,38% com dados brutos, comparável aos 93,54% reportados no estudo [17]. De forma similar, o modelo ResNet-50 alcançou uma acurácia de 96,12% com dados brutos em nosso estudo, enquanto o estudo [18] relatou uma

acurácia de 97,97%. O modelo EfficientNet apresentou uma acurácia de 94,38% com dados brutos no presente estudo, em contraste com os 92,50% observados no estudo [20]. Esses resultados sugerem que, apesar de nossos modelos estarem próximos dos melhores desempenhos documentados, ainda há espaço para refinamento e melhorias adicionais.

## VI. CONCLUSÃO

O estudo avaliou a eficácia de três arquiteturas de Redes Neurais Convolucionais (AlexNet, ResNet-50 e EfficientNet) na classificação de imagens de tomografia computadorizada de câncer de pulmão utilizando o conjunto de dados IQ-QTH/NCC [12]. Os resultados indicaram que, em 100 épocas, o modelo AlexNet alcançou a melhor acurácia com o filtro CLAHE, apresentando uma acurácia de 96,82%, enquanto a ResNet-50 foi mais eficaz ao aplicar o filtro de Wavelet, com um valor de acurácia de 80,74%. Além disso, a ResNet-50 continuou sendo a arquitetura mais precisa ao lidar com dados brutos ao longo das 100 épocas, apresentando uma acurácia de 94,44%

Para o *dataset* LIDC-IDRI [13], os resultados indicam que, em 100 épocas, o modelo ResNet-50 apresentou o melhor valor de acurácia nos dados brutos, alcançando 97,80%. Já o modelo EfficientNet obteve acurácia superior aos demais modelos utilizando os filtros de Wavelet e CLAHE, com valores de acurácia respectivos de 95,40% e 97,30%.

Portanto, os resultados indicam que os modelos EfficientNet e ResNet-50 são ferramentas promissoras para auxiliar profissionais de saúde na classificação de imagens de tomografia computadorizada de câncer de pulmão, permitindo prognósticos mais precisos e auxiliando na tomada de decisões clínicas. Para trabalhos futuros, pretende-se implementar a filtragem Wavelet de maneira mais abrangente para potencialmente melhorar a acurácia dos modelos propostos. Além disso, planeja-se incorporar a geração de mapas de calor para destacar as regiões mais relevantes nas imagens analisadas, o que pode fornecer informações adicionais valiosas para os profissionais de saúde.

TABELA III: COMPARAÇÃO DE DESEMPENHO DOS MODELOS PROPOSTOS COM O ESTADO DA ARTE

Arquitetura	Dados Brutos 100 épocas	Meu modelo			Métodos Propostos					
		ACC (%)	PREC(%)	REC(%)	ACC(%)	PREC(%)	REC(%)	ACC(%)	PREC(%)	REC(%)
AlexNet	Bruto	94,38%	97,50%	89,50%	93,54%	97,10%	93,15%	98,58%	96,78%	95,50%
ResNet-50	Bruto	96,12%	96,00%	97,00%	-	-	-	97,97%	95,91%	93,45%
EfficientNet	Bruto	94,38%	94,00%	85,00%	-	-	-	-	-	-

## REFERENCES

- [1] ORGANIZACIÓN PANAMERICANA DE LA SALUD - OPS. Tasa mortalidad. Washington, 2023. Disponível em: <https://www.paho.org/es/temas/cancer>. OPAS, Acesso em: 09 ago. 2024.
- [2] BRASIL. Ministério da Saúde. Instituto Nacional de Câncer - INCA. Cancer pulmon. Brasilia, DF, 2023. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/pulmao>. Data de acesso: 09 ago. 2024.
- [3] SOCIEDADE BRASILEIRA DE RADIOTERAPIA - SBRT. Fila de espera por exames na capital. 2023. Disponível em: [https://sbradioterapia.com.br/wp-content/uploads/2024/01/Nota\\_Oficial\\_SBRT\\_01-2024.pdf](https://sbradioterapia.com.br/wp-content/uploads/2024/01/Nota_Oficial_SBRT_01-2024.pdf). Acesso em: 09 ago. 2024.
- [4] CHIU, H.-Y. et al. Artificial intelligence for early detection of chest nodules in x-ray images. *Biomedicines*, Basel, v. 10, n. 11, p. 15, 2022.
- [5] BRASIL. Ministério da Saúde. comissão nacional de incorporação de tecnologias (CONITEC). Relatório para sociedade: informações sobre recomendações de incorporação de medicamentos e outras tecnologias no SUS: Disponível em: [https://www.gov.br/conitec/pt-br/mídias/consultas/relatórios/2023/sociedade/20230725\\_resoc\\_415\\_alectinibe\\_cancer\\_de\\_pulmao.pdf](https://www.gov.br/conitec/pt-br/mídias/consultas/relatórios/2023/sociedade/20230725_resoc_415_alectinibe_cancer_de_pulmao.pdf). Acesso em: 09 ago. 2024.
- [6] NEOPLASIA: O que é, sintomas e diferença entre maligno ou benigno. Tua saúde, abril de 2023. Disponível em: <https://www.tuasaude.com/o-que-e-neoplasia-tumor-e-cancer/:text=O%20tumor%20benigno%20%C3%A9%20uma%20neoplasia%20de%20crescimento,quando%20o%20est%C3%ADmulo%20que%20o%20causou%20%C3%A9%20removido>. Acesso em: 09 ago. 2024.
- [7] KROHN, J. Deep learning illustrated. London: AddisonWesley, 2020.
- [8] ARIF, T. M.; RAHIM, A. Deep Learning for Engineers. Boca Raton: CRC, 2024.
- [9] X. Wang, Y. Zhao e F. Pourpanah, “Recent advances in deep learning,” *International Journal of Machine Learning and Cybernetics*, vol. 11, p. 747–750, 2020.
- [10] KELLEHER, J. D. Deep learning. Cambridge: The MIT Press, 2019. Citado 5 vezes nas páginas
- [11] M. A. Wani, F. A. Bhat, S. Afzal, and A. I. Khan, *Advances in Deep Learning*, 1st ed., ser. *Studies in Big Data*. Springer Singapore, 2020. [Online]. Available: <https://doi.org/10.1007/978-981-13-6794-6>
- [12] Alyasriy, Hamdalla (2020), “The IQ-OTHNCCD lung cancer dataset”, Mendeley Data, V1, doi: 10.17632/bhmdr45bh2.1
- [13] Armato, S.G., III, McLennan, G., Bidaut, L., McNitt-Gray, M.F., Meyer, C.R., Reeves, A.P., Zhao, B., Aberle, D.R., Henschke, C.I., Hoffman, E.A., Kazerooni, E.A., MacMahon, H., van Beek, E.J.R., Yankelevitz, D., Biancardi, A.M., Bland, P.H., Brown, M.S., Engelmann, R.M., Laderach, G.E., Max, D., Pais, R.C., Qing, D.P.-Y., Roberts, R.Y., Smith, A.R., Starkey, A., Batra, P., Caligiuri, P., Farooqi, A., Gladish, G.W., Jude, C.M., Munden, R.F., Petkovska, I., Quint, L.E., Schwartz, L.H., Sundaram, B., Dodd, L.E., Fenimore, C., Gur, D., Petrick, N., Freymann, J., Kirby, J., Hughes, B., Vande Castele, A., Gupte, S., Sallam, M., Heath, M.D., Kuhn, M.H., Dhariaya, E., Burns, R., Fryd, D.S., Salganicoff, M., Anand, V., Shreter, U., Vastagh, S., Croft, B.Y. and Clarke, L.P. (2011), The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A Completed Reference Database of Lung Nodules on CT Scans. *Med. Phys.*, 38: 915-931. <https://doi.org/10.1118/1.3528204>
- [14] S. Pizer, R. Johnston, J. Erickson, B. Yankaskas, and K. Muller, “Contrast-limited adaptive histogram equalization: speed and effectiveness,” in [1990] Proceedings of the First Conference on Visualization in Biomedical Computing, 1990, pp. 337–345.
- [15] F. Rodrigues, F. Patrício, E. Oliveira, and A. Paula, *Desafios do manejo no controle de doenças do café- F I TOSSA N I DA D E*, 03 2019, pp. 52– 54.
- [16] BELCIUG, S. Artificial intelligence in cancer: diagnostic to tailored treatment. Cambridge: Academic, 2020.
- [17] H. F. Al-Yasriy, M. S. AL-Husieny, F. Y. Mohsen, E. A. Khalil, and Z. S. Hassan, “Diagnosis of Lung Cancer Based on CT Scans Using CNN,” *\*IOP Conference Series: Materials Science and Engineering\**, vol. 928, no. 2, pp. 022035, Nov. 2020. DOI 10.1088/1757-899X/928/2/022035
- [18] Narin, D., & Onur, T. Ö. (2022). The Effect of Hyper Parameters on the Classification of Lung Cancer Images Using Deep Learning Methods. *Erzincan University Journal of Science and Technology*, 15(1), 258-268. <https://doi.org/10.18185/erzifbed.1006560>
- [19] M. A. Wani, F. A. Bhat, S. Afzal, and A. I. Khan, *Advances in Deep Learning*, 1st ed., ser. *Studies in Big Data*. Springer Singapore, 2020. [Online]. Available: <https://doi.org/10.1007/978-981-13-6794-6>
- [20] Suji, R.J., Godfrey, W.W. & Dhar, J. Explorando codificadores pré-treinados para tarefa de segmentação de nódulos pulmonares usando o conjunto de dados LIDC-IDRI. *Ferramentas Multimed Appl* 83, 9685–9708 (2024). <https://doi.org/10.1007/s11042-023-15871-3>