

# PavicNet-MC: Um modelo de classificação *multilabel* aplicado em ultrassonografia pulmonar

Clécio Elias Silva e Silva<sup>1</sup>, Salomão Mafalda Machado<sup>1</sup>, Ana Beatriz Alvarez<sup>1</sup>,  
Roger Fredy Larico Chavez<sup>1</sup>

<sup>1</sup>Centro De Ciências Exatas e Tecnológicas – Universidade Federal do Acre (UFAC)  
Rio Branco – AC – Brasil

{clecio.silva, salomao.machado}@sou.ufac.br, {ana.alvarez, roger.fredy}@ufac.br

**Abstract.** *In recent years, the consequences of Covid-19 and other lung diseases have caused an increase in demand for health services, early and accurate diagnosis of these diseases is essential for the recovery of patients. This article proposes a multilabel classification model, called PavicNet-MC. This model was developed with the aim of identifying five features visible on lung ultrasound. The proposed model obtained an accuracy of 99% in the classification of the five characteristics. Results show that the proposed model is highly effective in detecting and monitoring the visible features that correlate with lung diseases, and has a relatively low complexity compared to other architectures found in the literature.*

**Resumo.** *Nos últimos anos as consequências da Covid-19 e outras doenças pulmonares vem causando um aumento na demanda pelos serviços de saúde, o diagnóstico precoce e preciso dessas doenças é essencial para a recuperação dos pacientes. Este artigo propõe um modelo de classificação multirrotulo, denominado PavicNet-MC. Este modelo foi desenvolvido com a motivação de identificar cinco características visíveis em ultrassonografia pulmonar. O modelo proposto obteve uma precisão de 99% na classificação das cinco características. Resultados mostram que o modelo proposto é altamente eficaz na detecção e monitoramento das características visíveis que se correlacionam com doenças pulmonares, e possui uma complexidade relativamente baixa em comparação com outras arquiteturas encontradas na literatura.*

## 1. Introdução

A pandemia de COVID-19 tem causado um aumento significativo na demanda por serviços de saúde em todo o mundo e o diagnóstico preciso e o tratamento oportuno são fundamentais para garantir a segurança dos pacientes infectados. As vacinas para a doença vêm demonstrando enorme eficácia, porém, essa demanda continua alta [Delardas et al. 2022]. Doenças pulmonares representam uma ameaça particularmente séria devido à sua capacidade de causar danos graves aos pulmões e à sua alta taxa de mortalidade [Zayet et al. 2020]. Os sintomas de COVID-19, como falta de ar, tosse e febre, são semelhantes a de outras doenças pulmonares, como pneumonia e bronquite, o que pode tornar o diagnóstico difícil [Zayet et al. 2020].

O diagnóstico precoce de doenças pulmonares é essencial para garantir que os pacientes recebam o tratamento adequado e aumentem suas chances de recuperação. No

entanto, o diagnóstico dessas doenças pode ser difícil devido a características e sintomas semelhantes, como também às limitações dos métodos de diagnóstico atuais, como radiografias, ultrassonografia e tomografias. Essas técnicas podem ser insuficientes para detectar corretamente doenças pulmonares no estágio inicial, e isso pode levar a um diagnóstico tardio e a um prognóstico pior para os pacientes, o que torna ainda mais importante a implementação de ferramentas que possam ajudar no diagnóstico [Wang et al. 2021].

A utilização da visão computacional (VC) e da Inteligência Artificial (IA) na área médica sempre foi vista com desconfiança devido à incerteza em relação à precisão dos resultados e à falta de dados médicos disponíveis para treinar os modelos. No entanto, nos últimos anos, houve um aumento significativo no volume de dados médicos disponíveis e na capacidade de processamento das máquinas, permitindo soluções cada vez mais precisas e confiáveis [Fourcade and Khonsari 2019].

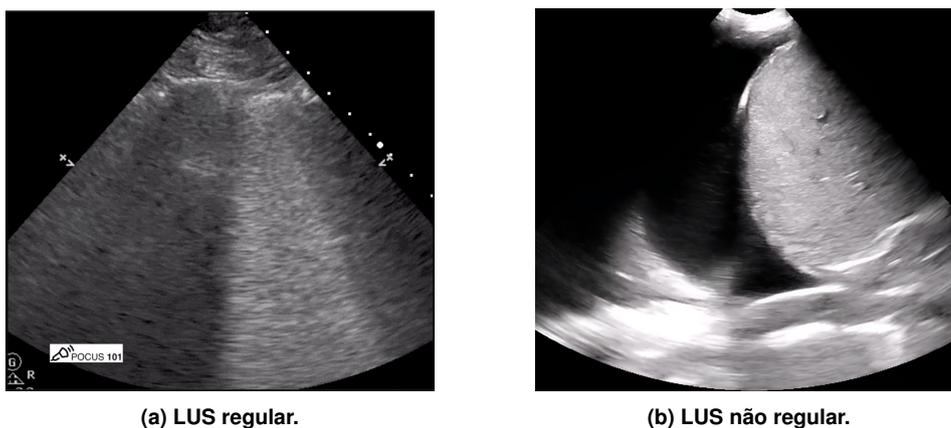
A crescente demanda por soluções mais eficientes e acessíveis para o diagnóstico e tratamento de doenças tem aumentado o interesse por soluções baseadas em *deep learning*, a utilização dessa tecnologia na área médica é vista como uma importante ferramenta para aprimorar diagnósticos, prevenir doenças e melhorar o tratamento dos pacientes, como demonstrado pela grande quantidade de artigos publicados na área [Alshmrani et al. 2023] e [Diaz-Escobar et al. 2021].

A utilização de ultrassonografia pulmonar (LUS) é uma área promissora para a aplicação de tecnologias de *deep learning* (DL). Estas ultrassonografias contêm informações valiosas sobre a estrutura e a função pulmonar do paciente, mas a interpretação dessas imagens pode ser um desafio para os médicos. A utilização de algoritmos de DL pode ajudar a superar esses desafios, auxiliando os médicos na obtenção de mais informações sobre a saúde de seus pacientes [Liu et al. 2019].

A ultrassonografia é amplamente utilizada no diagnóstico médico, devido às suas várias vantagens, como a capacidade de fornecer imagens em tempo real, ser relativamente barata, não invasiva e de fácil utilização [Zhao and Lediju Bell 2022]. A Figura 1 mostra dois exemplos de ultrassonografias pulmonar para um pulmão regular e um pulmão não regular. Entretanto, a ultrassonografia também apresenta algumas desvantagens, como a presença de artefatos e ruídos fortes nas imagens, que podem afetar a qualidade dos diagnósticos. Além disso, a interpretação das imagens de ultrassonografia é altamente dependente da habilidade e experiência dos médicos. Apesar dessas limitações, a ultrassonografia continua sendo uma ferramenta valiosa para o diagnóstico e monitoramento de várias condições médicas, especialmente em áreas como obstetrícia, cardiologia, gastroenterologia e urologia [Wang et al. 2021].

A partir das imagens é possível notar as características visíveis, que podem ajudar no diagnóstico de diversas condições pulmonares. Em resumo, tais características são formas geradas a partir da onda de ultrassom ao traçar certas estruturas com diferentes propriedades acústicas [Moore and Gardiner 2020]. Algumas das anomalias mais comuns que podem ser vistas em uma imagem de ultrassonografia incluem: linha pleural, linhas A, linhas B, derrame pleural, consolidação pulmonar e irregularidades pleurais (detalhado na sessão 3).

Este artigo apresenta o modelo PavicNet-MC (desenvolvido por pesquisadores do laboratório PAVIC), destinado à classificação *multilabel* (ou multirrótulo em português)



**Figura 1. Ultrassonografias pulmonar com um exemplo de um pulmão regular (a), e um pulmão não regular com características típicas de derrame pleural.**

de ultrassonografias de pulmão com alta eficiência. Utilizando *deep learning* e *machine learning* para à análise de ultrassonografia pulmonar, este modelo é capaz de detectar a presença ou ausência de 5 tipos diferentes de características ou artefatos visíveis que se correlacionam com algum tipo de doença pulmonar, sendo elas: linhas A, linhas B, derrame pleural, consolidação pulmonar e irregularidades pleurais (B lines, A lines, Effusion, Consolidation e Pleural Irregularities). Além disso, o modelo proposto possui uma complexidade reduzida devido a menor quantidade de parâmetros quando comparado com arquiteturas clássicas. O PavicNet-MC poderá ter um impacto significativo no auxílio ao diagnóstico de doenças pulmonares sem ter a necessidade de um enorme poder computacional, além de poder ser usado para outros trabalhos de classificação *multilabel*.

## 2. Trabalhos Relacionados

Desde o surto de COVID-19, houve um interesse crescente na pesquisa de modelos de DL para diagnóstico de doenças pulmonares que se demonstraram promissores na detecção de várias doenças pulmonares inclusive da própria COVID-19 [Brunese et al. 2020]. Alguns dos primeiros trabalhos nesse campo enfocaram o uso de técnicas de processamento de imagem para detectar anormalidades em radiografias ou ultrassonografias pulmonares, como a utilização de transferência de aprendizado ou transformações matemáticas para obter resultados com estas imagens.

Diaz-Escobar et al. (2021) apresentaram modelos de aprendizado profundo pré-treinados e treinados com imagens de ultrassonografia pulmonar de pacientes saudáveis, com COVID-19 e com pneumonia para detecção das três classes. Os resultados mostraram que os modelos de aprendizado de máquina são uma abordagem viável para a detecção de doenças pulmonares a partir de ultrassonografia, destacando a eficiência e a rapidez do modelo InceptionV3. No entanto, o estudo também demonstrou que há um grande espaço para a melhora desses modelos, considerando a complexidade das redes neurais. A importância das ultrassonografias na detecção de doenças pulmonares e o uso de técnicas de aprendizado de máquina são cruciais para diagnósticos precisos e rápidos [Szegedy et al. 2016]. A possibilidade de reduzir a complexidade destas redes neurais também se torna um objetivo [Diaz-Escobar et al. 2021].

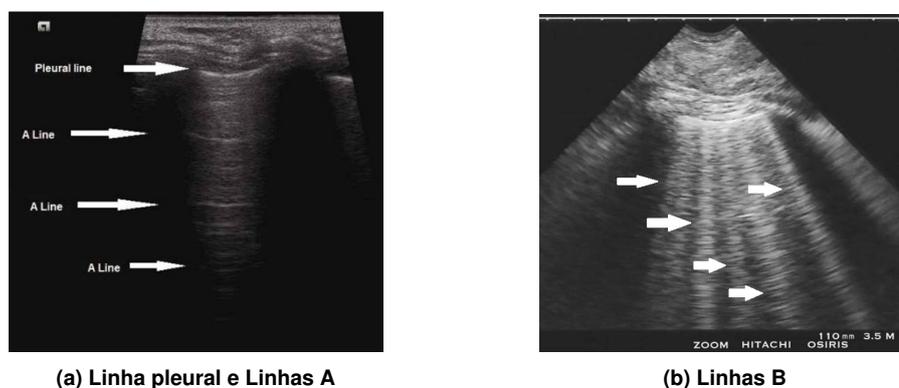
Ullah et al. (2022) propuseram o modelo CovidDetNet para a classificação da

COVID-19 e pneumonia utilizando imagens de radiografia de tórax. O estudo destacou a importância da detecção precoce para a prevenção de novos casos da COVID-19, além de enfatizar a necessidade de um sistema de diagnóstico rápido e preciso. O CovidDet-Net demonstrou uma alta precisão na detecção e classificação da COVID-19 e pneumonia, enfatizando a importância das imagens de radiografia na detecção precoce de doenças pulmonares [Ullah et al. 2022]. Apesar disso, a ultrassonografia ainda é uma das modalidades de imagem mais utilizadas no diagnóstico médico, tem as vantagens de ser em tempo real, um baixo custo, natureza não invasiva e fácil de se operar [Zhao and Lediju Bell 2022].

Em resumo, a importância das imagens de ultrassonografia e radiografia na detecção precoce de doenças pulmonares é fundamental, especialmente durante a pandemia da COVID-19. O uso de técnicas de aprendizado de máquina, como a transferência de aprendizado e modelos pré-treinados, é uma abordagem viável para melhorar a eficiência do diagnóstico. No entanto, é essencial melhorar a precisão e a complexidade das arquiteturas escolhidas para que a rede possa ser usada em larga escala e com êxito.

### 3. Características Visíveis na Ultrassonografia

A **linha pleural**, uma das características mais importantes e observadas na ultrassonografia pulmonar, é um artefato hiperecoico horizontal, visualizado cerca de meio centímetro abaixo das costelas, representando a pleura parietal, e é vista mais facilmente quando a sonda é colocada longitudinalmente na parede torácica (Figura 2.a).



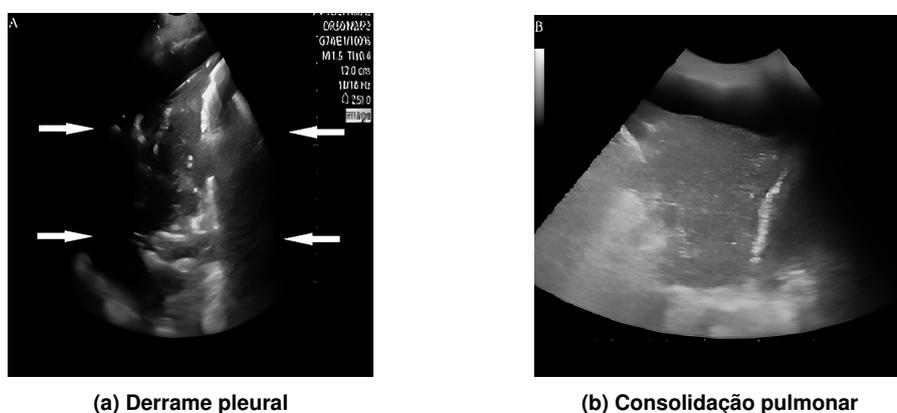
**Figura 2. a) Ultrassonografia pulmonar, mostrando a linha pleural e as linhas A. b) Ultrassonografia pulmonar, mostrando as linhas B.**

As **linhas A** são definidas como linhas ecogênicas que diminuem gradualmente em intensidade, formando uma disposição horizontal em intervalos regulares abaixo da linha pleural. Essas linhas são um exemplo do artefato de repetição da pleura parietal e são usadas como um indicador para avaliar a condição pulmonar. A distância entre essas linhas é quase igual à distância entre a superfície da pele e a linha pleural. Essas linhas são observadas tanto no pulmão saudável quanto no pneumotórax, sua presença geralmente é devida à presença de ar/gás abaixo da pleura (Figure 2.a) [Saraogi 2015]. Sua ausência também pode indicar que a fisiologia pulmonar sofreu alguma alteração, de modo que o tecido pulmonar passou a transmitir ondas sonoras em um padrão diferente do fisiológico.

As **linhas B**, também chamadas de caldas de cometas pulmonares em ultrassonografia, são artefatos de reverberação vertical que surgem a partir da linha pleural e

se estendem até a profundidade da imagem, em perpendicular às linhas A (Figura 2.b). [Bhoil et al. 2021]. Elas mantêm sua intensidade ao longo do seu trajeto e se movem de maneira coordenada com o deslizamento pulmonar. As linhas B só podem ser vistas na interface acústica da pleura/tecido [Lichtenstein et al. 2009]. As linhas B podem ou não estarem relacionadas à algumas enfermidades, como por exemplo a Síndrome intersticial [Saraogi 2015].

Um **derrame pleural** acontece quando uma coleção de líquido se acumula no espaço pleural, o fluido se acumula na parte mais baixa do tórax. Geralmente, em imagens de ultrassonografia, o derrame pleural aparece como um espaço anecoico entre a pleura (Figure 3.a). Porém, se houver a presença de ecos internos neste espaço, pode indicar exsudato ou hemorragia, e é necessário realizar um procedimento chamado toracocentese para confirmar [Saraogi 2015].



**Figura 3.** a) Ultrassonografia pulmonar, mostrando um derrame pleural (área anecóica entre as setas brancas). b) Ultrassonografia pulmonar, mostrando uma consolidação pulmonar (área opaca no lobo inferior esquerdo do pulmão).



**Figura 4.** Ultrassonografia pulmonar mostrando uma linha pleural irregular (retângulo branco).

A **consolidação pulmonar** geralmente ocorre quando o ar que preenche as pequenas vias aéreas dos pulmões é substituído por algo líquido ou sólido, como água, pus, sangue ou conteúdo do estômago. Em uma imagem de ultrassonografia, a aparência da consolidação pode variar de acordo com o estágio ou a causa, mas geralmente ela é visu-

alizada como uma área hipoecoica com uma aparência sólida ou homogênea (Figure 3.b) [Gehmacher et al. 1995].

As **irregularidades pleurais** são condições em que a pleura apresenta alterações em sua estrutura ou função, como pode ser visualizado na Figura 4, que mostra um exemplo da linha pleural irregular. Algumas das anomalias pleurais mais comuns incluem espessamento pleural, hemotórax e síndrome intersticial, que aparece como um conjunto de linhas B. A ultrassonografia é uma ferramenta útil para detectar e diagnosticar essas anomalias, permitindo um tratamento mais preciso e eficaz. [Lichtenstein and Meziere 2008].

## 4. Materiais e Métodos

### 4.1. Hardware e Software

O ambiente de execução utilizado para os experimentos relacionados ao modelo PavicNet-MC foi o Google Colab e a linguagem Python. Os recursos do ambiente Google Colab incluem uma GPU do modelo Nvidia K80, 12GB de memória RAM e uma CPU do modelo Intel(R) Xeon(R). Para a construção e treinamento do modelo foi utilizado a biblioteca TensorFlow<sup>1</sup> em conjunto com sua API Keras<sup>2</sup>, além das bibliotecas comumente usadas: Scikit Learn<sup>3</sup>, Pandas<sup>4</sup>, Numpy<sup>5</sup> e OpenCV<sup>6</sup>.

### 4.2. Banco de Imagens

As imagens utilizadas para o treinamento do modelo foram compostas a partir de vídeos fornecidos pelo dataset POCUS [Born et al. 2020], no total foram utilizados 165 vídeos selecionados, aos quais foram transformados em imagens através de uma função onde foram selecionados 20 frames por vídeo, totalizando 3300 imagens, e por fim foram divididas em um conjunto de treino e um conjunto de teste. Foram selecionadas as cinco classes de características de doenças pulmonares já mencionadas, linhas A, linhas B, derrame pleural, consolidação pulmonar e irregularidades pleurais.

O conjunto de treino, foi composto por 80% das imagens, enquanto o conjunto de teste foi composto por 20% das imagens restantes e utilizado para a avaliação de desempenho do modelo. Cabe ressaltar que todas as imagens foram convertidas para escala de cinza e dimensão 224x224x1.

### 4.3. Métricas de Avaliação

Para a avaliação do modelo PavicNet-MC foi utilizado a matriz de confusão, acurácia, sensibilidade, precisão e a curva *ROC (Receiver Operating Characteristic)*.

A matriz de confusão é uma ferramenta importante para analisar o desempenho de um modelo de classificação, permitindo a identificação de falsos negativos, falsos positivos, verdadeiros positivos e verdadeiros negativos (FN, FP, VP, VN). A matriz é gerada comparando os valores verdadeiros com os valores previstos para cada classe, e apresentando-os em uma tabela que mostra a frequência de cada tipo de classificação.

---

<sup>1</sup><https://www.tensorflow.org>

<sup>2</sup><https://keras.io/>

<sup>3</sup><https://scikit-learn.org/stable/index.html>

<sup>4</sup><https://pandas.pydata.org/docs/index.html>

<sup>5</sup><https://numpy.org/>

<sup>6</sup><https://opencv.org/>

A curva *ROC* é uma ferramenta gráfica que mostra a relação entre a sensibilidade e a taxa de falsos positivos (FPR) do modelo para diferentes limiares de classificação. A curva ROC é criada plotando a taxa de verdadeiros positivos (TPR) em relação à taxa de falsos positivos (FPR) para diferentes limiares de classificação.

A acurácia é uma medida que indica a porcentagem de previsões corretas em relação ao total de previsões realizadas pelo modelo. A acurácia é calculada a partir da matriz de confusão com a proporção de exemplos que foram classificados corretamente pelo modelo em relação ao número total de exemplos, como pode ser visualizado na equação (1), se calcula a acurácia com a soma dos valores verdadeiros positivos  $VP$  com os verdadeiros negativos  $VN$ , em relação a soma dos valores verdadeiros positivos  $VP$ , verdadeiros negativos  $VN$ , falsos positivos  $FP$  e falsos negativos  $FN$ .

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

A sensibilidade é uma métrica que mede a proporção de verdadeiros positivos  $VP$  em relação ao total de exemplos positivos reais (verdadeiros positivos  $VP$  e falsos negativos  $FN$ , como visto na equação (2)). Em outras palavras, a sensibilidade mede a capacidade do modelo de identificar corretamente os exemplos positivos.

$$Sensibilidade = \frac{VP}{VP + FN} \quad (2)$$

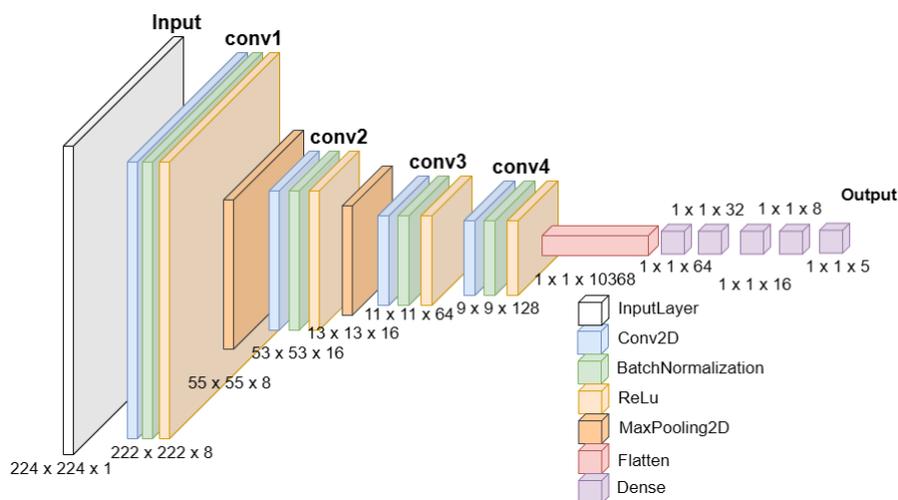
A precisão refere-se à medida de desempenho que indica a proporção de amostras que foram classificadas corretamente pelo modelo em relação ao número total de amostras positivas. Como pode ser observado na equação (3), a precisão é calculada a partir da relação entre verdadeiros positivos  $VP$  e a soma dos verdadeiros positivos  $VP$  e falsos positivos  $FP$ .

$$Precisão = \frac{VP}{VP + FP} \quad (3)$$

#### 4.4. Arquitetura do Modelo PavicNet-MC

A arquitetura do modelo é composta principalmente por camadas de convolução e densas. As primeiras extraem informações básicas, seguidas por uma camada de *Max pooling*. Depois, há mais camadas de convolução e *Max pooling* antes da camada *Flatten*, que transforma os dados em um vetor linha para a classificação *multilabel*.

De forma mais detalhada, a primeira camada de convolução tem 8 filtros e tamanho de kernel 3x3. Ela recebe a imagem de entrada com tamanho 224x224x1, que representa o canal de cor em escala de cinza. Em seguida, a camada de *BatchNormalization* normaliza os dados a fim de melhorar a estabilidade da rede e acelerar o treinamento. A função de ativação *Rectified Linear Unit* (ou *ReLU*) é aplicada para introduzir não-linearidade e aumentar a capacidade de representação da rede. Por fim, a camada de *Max pooling* foi adicionada para reduzir a dimensionalidade da imagem de entrada para 55x55x8.



**Figura 5. Arquitetura do modelo PavicNet-MC**

A segunda camada de convolução segue o mesmo padrão da primeira, após a camada de *Max pooling*, com tamanho de 53x53x16. Essa camada extrai características mais complexas que a primeira, com um maior número de filtros para processar informações adicionais.

Há, em seguida, uma camada de *Max pooling* e mais duas camadas de convolução com 64 e 128 filtros, respectivamente, e como pode ser visto na Figura 5, tem tamanhos de 11x11 e 9x9. Posteriormente, foi adicionado a camada *Flatten* para que possam ser processados pelas camadas densas. As camadas densas possuem 64, 32, 16, 8 e 5 neurônios, respectivamente. A função de ativação *ReLU* foi aplicada em todas as camadas densas, exceto na última camada, que utiliza a função de ativação *Sigmoid*. O modelo apresentou aproximadamente 751,653 parâmetros, relativamente pouco comparado a arquiteturas clássicas. A Figura 5 representa graficamente a arquitetura desenvolvida.

O código completo desenvolvido para o treinamento e avaliação do PavicNet-MC está disponível em um repositório no GitHub, que pode ser acessado por meio do seguinte link: <https://github.com/Cleps/PavicNet-MC>. Com isso, é possível reproduzir e adaptar o modelo para diferentes cenários de aplicação.

#### 4.5. Treinamento do Modelo

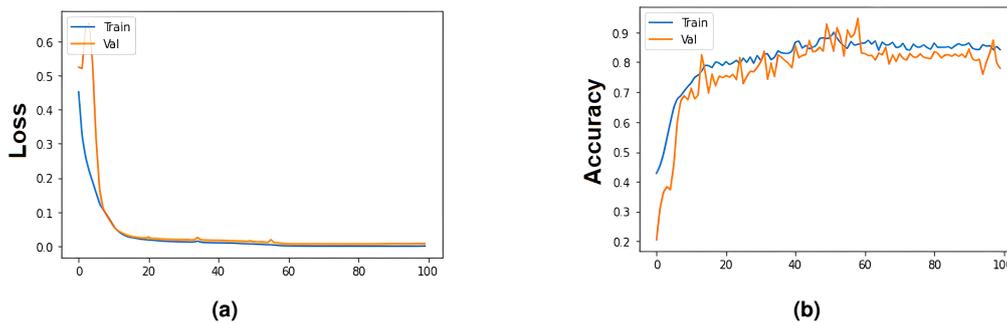
De acordo com a Tabela 1, o modelo foi treinado com 100 épocas, que levaram aproximadamente 15 segundos cada. O *Input size* utilizado foi de 224x224 com 1 só canal de entrada. Foi usada a função de perda *binary crossentropy*, com um *learning rate* de 0.0001 e a função de otimização *Adam*. Também foi utilizado ultrassonografias torácicas como já mencionado e rótulos que indicam a presença ou ausência de cada uma das 5 características de doenças. A Figura 6 mostra os gráficos de perda e acurácia do modelo durante as 100 épocas do treinamento.

### 5. Resultados

Após avaliar a curva *ROC* do modelo (Figura 7), verificou-se que a *AUC (Area Under the Curve)* para todas as 5 características é igual a 1.00, o que indica que o modelo apresentou uma classificação satisfatória, mantendo uma alta taxa de verdadeiros positivos e uma

**Tabela 1. Tabela de hiperparâmetros**

Hiperparâmetro	Valor
<i>Input size</i>	224x224
<i>Channels</i>	1
<i>Optimizer</i>	Adam
<i>Learning rate</i>	0.0001
<i>Loss function</i>	<i>binary crossentropy</i>
<i>Epochs</i>	100



**Figura 6. A Figura mostra os gráficos da perda (a) e da acurácia (b) de treinamento e validação do modelo ao longo das 100 épocas.**

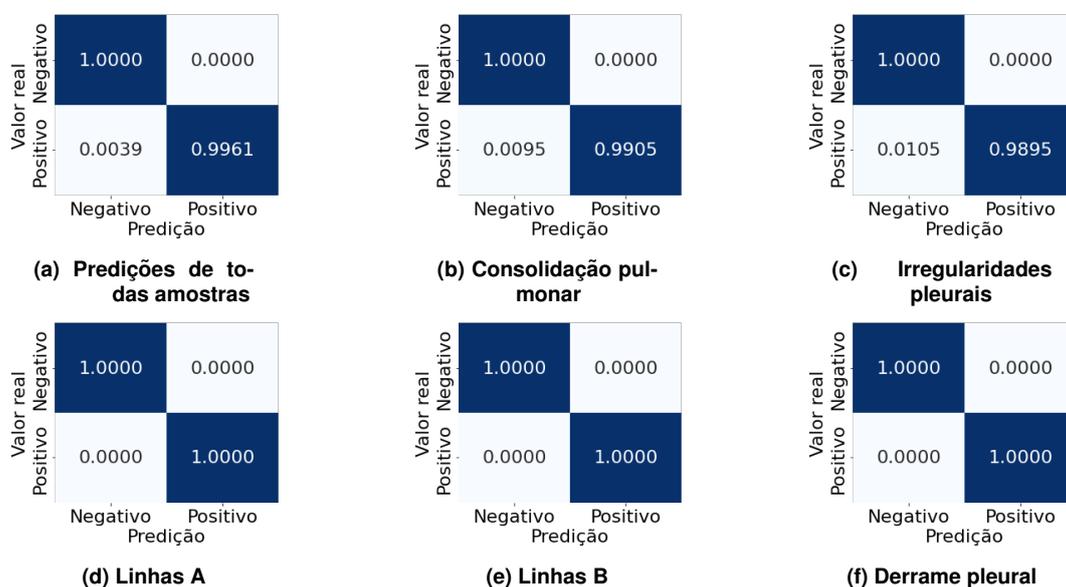
baixa taxa de falsos positivos em todos os pontos de corte. O resultado da *AUC* pode ser um indicador de *overfitting*, o que significa que o modelo pode estar ajustando demais os dados de treinamento e, portanto, não generalizando bem para novos dados. Porém, é importante usar a curva *ROC* em conjunto com outras métricas para avaliar completamente a performance do modelo e como pode ser visto na Figura 6, o treinamento e avaliação do modelo durante as épocas não mostrou diferenças significativas em relação ao padrão, indicando que o modelo não apresenta *overfitting*.



**Figura 7. Curva ROC do modelo**

Podemos ver de modo geral o desempenho do modelo a partir de sua matriz de confusão (Figura 8). A matriz de confusão para todas as características classificadas (Figura 8.a) apresentou 0,9961 de classificações verdadeiras positivas, o que representa 99,61% das amostras. Como pode ser observado na Figura 8, as matrizes de confusão de irregularidades pleurais (Figura 8.c) e consolidações pulmonar (Figura 8.b) foram as únicas a apresentarem resultados com falsos negativos, sendo 0,0095 e 0,0105, o que representa 0,95% e 1,05% das amostras respectivamente. O restante das matrizes demons-

traram que o modelo classificou com sucesso todas amostras restantes (Figura 8.d-f).



**Figura 8. Matriz de confusão de todas as predições feitas pelo modelo (a) e matrizes de confusão para cada característica classificada pelo modelo (b-f)**

Os valores da acurácia variam entre 0,997 e 1,0, que representam 99,7% e 100% respectivamente. A categoria de derrame pleural, apresentou uma acurácia ligeiramente menor do que as outras, com um valor de 0,9985, o mesmo para consolidação pulmonar que teve um valor de 0,997. A precisão para as outras categorias, linhas A, linhas B e irregularidades pleurais, foi de 1,0, indicando que o modelo classificou com sucesso todas as amostras nessas categorias, como pode ser observado na Tabela 2.

Nota-se que o modelo teve sucesso em todas as amostras com linhas A, linhas B e derrame pleural. Em consolidação pulmonar e irregularidades pleurais, o modelo teve uma sensibilidade de 0,99 e 0,98, que representa 99% e 98,9% respectivamente.

O modelo foi capaz de classificar corretamente todas as amostras positivas para as cinco características avaliadas, bem como todas as amostras negativas que não apresentavam nenhuma das características visíveis, alcançando uma precisão de 1,0, que indica 100%.

**Tabela 2. Resultados do modelo PavicNet-MC**

Características	Acurácia	Sensibilidade	Precisão
Linhas A	1.0	1.0	1.0
Linhas B	1.0	1.0	1.0
Derrame pleural	1.0	1.0	1.0
Consolidações pulmonar	0.99	0,99	1.0
Irregularidades pleurais	0.99	0,98	1.0

## 6. Conclusão e Considerações Finais

Com base nos resultados obtidos neste estudo, pode-se concluir que o modelo de rede neural proposto é altamente eficaz na classificação *multilabel* de características de doenças pulmonares a partir da ultrassonografia pulmonar. A acurácia alcançada pelo modelo demonstrou seu potencial para auxiliar na detecção precoce e no monitoramento de doenças pulmonares conforme mostrado na Tabela 1.

É importante também destacar que o modelo apresenta uma baixa complexidade, com aproximadamente 700 mil parâmetros. Tal valor é consideravelmente inferior quando comparado com outras arquiteturas de redes neurais mais leves, como as CNNs. Por exemplo, a InceptionV3 possui cerca de 23 milhões de parâmetros [Szegedy et al. 2016], enquanto a DenseNet201 tem cerca de 56 milhões de parâmetros [Huang et al. 2017], ambas amplamente utilizadas em trabalhos semelhantes. Portanto, a simplicidade do modelo proposto juntamente com sua alta eficiência o torna ainda mais atraente.

Embora a ultrassonografia tenha algumas limitações, como a presença de artefatos e a dependência da habilidade e experiência dos médicos na interpretação das imagens, ela continua sendo uma ferramenta valiosa no diagnóstico e monitoramento de várias condições médicas, principalmente se aliadas com visão computacional e aprendizado de máquina.

Os resultados deste estudo podem ter importantes implicações na prática clínica, uma vez que o modelo de rede neural PavicNet-MC pode ser usado como uma ferramenta complementar aos métodos de diagnóstico tradicionais, como ultrassonografias e radiografias. Além disso, a utilização de redes neurais para análise de imagens de ultrassonografia pulmonar pode ajudar a reduzir a variabilidade entre os médicos na interpretação das imagens, tornando o diagnóstico mais preciso e confiável.

## Agradecimentos

O presente estudo tem sua realização viabilizada graças ao suporte e recursos oferecidos pelo projeto de Pesquisa Aplicada em Visão Computacional e Inteligência Computacional da Motorola (PAVIC). Este trabalho tem o privilégio de contar com o apoio do PAVIC, o que o torna possível e promove a expansão do conhecimento na área de atuação.

## Referências

- Alshmrani, G. M. M., Ni, Q., Jiang, R., Pervaiz, H., and Elshennawy, N. M. (2023). A deep learning architecture for multi-class lung diseases classification using chest x-ray (cxr) images. *Alexandria Engineering Journal*, 64:923–935.
- Bhoil, R., Ahluwalia, A., Chopra, R., Surya, M., and Bhoil, S. (2021). Signs and lines in lung ultrasound. *Journal of Ultrasonography*, 21(86):225–233.
- Born, J., Brändle, G., Cossio, M., Disdier, M., Goulet, J., Roulin, J., and Wiedemann, N. (2020). Pocusnet: automatic detection of covid-19 from a new lung ultrasound imaging dataset (pocus). *arXiv preprint arXiv:2004.12084*.
- Brunese, L., Mercaldo, F., Reginelli, A., and Santone, A. (2020). Explainable deep learning for pulmonary disease and coronavirus covid-19 detection from x-rays. *Computer Methods and Programs in Biomedicine*, 196:105608.

- Delardas, O., Kechagias, K. S., Pontikos, P. N., and Giannos, P. (2022). Socio-economic impacts and challenges of the coronavirus pandemic (covid-19): An updated review. *Sustainability*, 14(15):9699.
- Diaz-Escobar, J., Ordóñez-Guillén, N. E., Villarreal-Reyes, S., Galaviz-Mosqueda, A., Kober, V., Rivera-Rodriguez, R., and Rizk, J. E. L. (2021). Deep-learning based detection of covid-19 using lung ultrasound imagery. *Plos one*, 16(8):e0255886.
- Fourcade, A. and Khonsari, R. H. (2019). Deep learning in medical image analysis: A third eye for doctors. *Journal of stomatology, oral and maxillofacial surgery*, 120(4):279–288.
- Gehmacher, O., Mathis, G., Kopf, A., and Scheier, M. (1995). Ultrasound imaging of pneumonia. *Ultrasound in medicine & biology*, 21(9):1119–1122.
- Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4700–4708.
- Lichtenstein, D. A. and Meziere, G. A. (2008). Relevance of lung ultrasound in the diagnosis of acute respiratory failure\*: the blue protocol. *Chest*, 134(1):117–125.
- Lichtenstein, D. A., Mezière, G. A., Lagoueyte, J.-F., Biderman, P., Goldstein, I., and Gepner, A. (2009). A-lines and b-lines: lung ultrasound as a bedside tool for predicting pulmonary artery occlusion pressure in the critically ill. *Chest*, 136(4):1014–1020.
- Liu, S., Wang, Y., Yang, X., Lei, B., Liu, L., Li, S. X., Ni, D., and Wang, T. (2019). Deep learning in medical ultrasound analysis: a review. *Engineering*, 5(2):261–275.
- Moore, S. and Gardiner, E. (2020). Point of care and intensive care lung ultrasound: a reference guide for practitioners during covid-19. *Radiography*, 26(4):e297–e302.
- Saraogi, A. (2015). Lung ultrasound: Present and future. *Lung India: Official Organ of Indian Chest Society*, 32(3):250.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2818–2826.
- Ullah, N., Khan, J. A., Almakdi, S., Khan, M. S., Alshehri, M., Alboaneen, D., and Raza, A. (2022). A novel covidnet deep learning model for effective covid-19 infection detection using chest radiograph images. *Applied Sciences*, 12(12):6269.
- Wang, Y., Ge, X., Ma, H., Qi, S., Zhang, G., and Yao, Y. (2021). Deep learning in medical ultrasound image analysis: a review. *IEEE Access*, 9:54310–54324.
- Zayet, S., Lepiller, Q., Zahra, H., Royer, P.-Y., Toko, L., Gendrin, V., Klopfenstein, T., et al. (2020). Clinical features of covid-19 and influenza: a comparative study on nord franche-comte cluster. *Microbes and infection*, 22(9):481–488.
- Zhao, L. and Lediju Bell, M. A. (2022). A review of deep learning applications in lung ultrasound imaging of covid-19 patients. *BME Frontiers*, 2022.