

Segmentação de Artefatos de Linha B em Imagens de Ultrassonografia Pulmonar Usando DeepLabV3+

Salomão Machado Mafalda

Universidade Federal do Acre
Rio Branco, Acre, Brasil
salomao.mafalda@sou.ufac.br

Roge Fredy Larico Chavez

Universidade Federal do Acre
Rio Branco, Acre, Brasil
roger.chavez@ufac.br

ABSTRACT

In recent years, lung ultrasound (LUS) has gained much importance in both the clinical and technological environments. This is because over the years it has been noticed that the presence of artifacts in the images correlates with a series of anomalies or diseases that affect the lungs. Therefore, assisting in the segmentation of these artifacts is of great clinical interest, as the prior identification of any anomaly can prevent its aggravation. Another challenging scenario, in particular, is that of emergency units, where fast and accurate diagnosis is essential, therefore, developing methods that facilitate the task of identifying anomalies through the segmentation of artifacts in images is of great importance. In this work, we train and compare the performance of three deep neural network architectures that can aid in clinical diagnosis by segmenting B-line artifacts in LUS images. These trained models are based on semantic segmentation, in which they perform semantic labeling at the pixel level. The architectures provided by DeepLabV3+ were used, they were: Resnet-18, Resnet-50 and Exception. These trained models were evaluated using the metric IoU (intersection over union), precision, accuracy, and sensitivity. In the end, the model that proved to be the most accurate was the one based on the Resnet-18 architecture, with an accuracy of 92.32%. Resnet-50 also showed satisfactory results, with a precision of 96.07% and a sensitivity of 91.39%.

KEYWORDS

Ultrassom, Segmentação Semântica, Processamento de Imagens, Linhas B

1 INTRODUÇÃO

Nos últimos anos a ultrassonografia pulmonar tem se tornado uma alternativa potencial na aplicação de tratamentos, exames e avaliação de pacientes nos setores de emergência e de medicina intensiva. Isso porque ao utilizar-se a ultrassonografia pulmonar notou-se que haviam diferenças significativas entre as imagens geradas de um pulmão regular para um pulmão que apresentava algum tipo de anomalia, tornando essa ferramenta muito útil no meio clínico. Outros pontos como a mobilidade, rapidez, ser não ionizante (não afetando assim a saúde do paciente), e a possibilidade de ser aplicada à beira do leito tornaram esse método ainda mais importante e aceito no meio clínico [1–3].

Em 2019 com o surgimento do vírus SARS-CoV-2 e seu rápido espalhamento em massa afetando todos continentes em poucos meses [3–6].

Essa pandemia causou milhares de casos de infecção e morte de pessoas, e continuamente esse número tem crescido, diversas abordagens surgiram para diagnosticar essa doença em seus estágios iniciais em tempo-real [4, 7].

Neste cenário, a ultrassonografia ganhou ainda mais importância e destaque pela sua rapidez e facilidade de utilização [4, 5, 8].

O objetivo de utilizar a ultrassonografia é a captura de artefatos nas imagens LUS que indiquem alguma anomalia pulmonar como, Covid-19, pneumonia, edema, efusão pulmonar, dentre outras doenças [9].

A Fig. 1a mostra uma imagem de ultrassonografia de um pulmão regular onde é possível notar a presença de alguns artefatos horizontais, também conhecidos como linha A, que se formam em função da grande diferença de densidade entre a pleura e o pulmão [3].


A Fig. 1b mostra uma imagem de ultrassonografia de um pulmão com a presença de linha B, indicando alguma anomalia pulmonar. Pode-se notar que a linha B é dada por um feixe de brilho que se propaga através das ondas de som, também conhecida como um artefato vertical hiperecoico que se originam a partir da linha pleural e situam-se perpendicularmente a esta. Além disso, as linhas B estão correlacionadas a uma gama de condições patológicas, geralmente relacionados a presença de água extravascular e doenças ou contusões pulmonares. Essas linhas tendem a desaparecer ou aparecer a depender da respiração do paciente, tornando assim desafiadora a identificação da mesma, especialmente para operadores inexperientes [1, 4, 9, 10].

Por outro lado, diversos avanços na área de processamento digital de imagens juntamente com inteligência computacional têm sido desenvolvidos para classificar, detectar e segmentar objetos. Quando aplicados às imagens médicas, o objetivo é classificar ou detectar automaticamente os artefatos, como por exemplo os artefatos de linha B, nas imagens de LUS [11].


Na literatura existem algumas abordagens para a detecção de artefatos de linha B em imagens de LUS. Trabalhos como em [5, 8, 12, 13] foram desenvolvidos envolvendo diversas técnicas que visaram detectar e/ou quantificar os artefatos de linha B presentes nas imagens. Em [2] um método automático de detecção e visualização de linhas B em imagens de LUS com foco na quantificação do número de linhas B presentes foi proposto.

Em [14, 15] um método de detecção de linhas B com uma técnica baseada na transformada de Radon e regularização de esparsidade também foi desenvolvido. Outro trabalho similar foi desenvolvido em [16] onde foi proposto um algoritmo com o objetivo de estimar linhas B com uma pontuação de 0 (sem linhas B) a 4 (Muitas linhas B), em tempo real.

Em [1] foram exploradas técnicas de aprendizado profundo supervisionado para detecção de linha B em tempo real utilizando uma GPU Titan Xp Nvidia. Uma rede neural totalmente conectada foi desenvolvida para treinar e reconhecer anormalidades em imagens seguido da geração do mapa de ativação (CAMs).



(a) Pulmão Regular



(b) Pulmão Irregular

Figura 1: Imagens de ultrassonografia pulmonar do banco de imagens ICLUS

Em [11] foi proposto um método convolucional que em vez de explorar *frames* de vídeos e ultrassonografia, analisava os vídeos em si extraindo informações temporais para capturar características dinâmicas da anatomia subjacente. Outra análise de atenção temporal para localizar os *frames* onde as linhas B apareciam também foi utilizada.

No estudo apresentado em [4] foi desenvolvida uma avaliação quantitativa comparando o desempenho de modelos utilizando segmentação semântica para o U-net, U-net++, DeepLabV3+ e a rede neural proposta ensemble. O modelo proposto por eles se mostrou capaz de segmentar e até mesmo discriminar em imagens de ultrassonografia pulmonar características que se relacionavam com pulmões regulares ou indicadores de Covid-19 com uma precisão de até 96%. Além disso, ficou visível que os modelos treinados realizaram predições de regiões positivas para Covid-19 que não haviam sido marcadas anteriormente. Neste trabalho, destacam a dificuldade das

marcações dos artefatos presentes nas imagens, dificultando assim uma avaliação precisa sobre o desempenho dos modelos, visto que, existiu muitas dúvidas se determinados artefatos deviam ou não serem marcados.

Foi aplicado em [17] uma classificação utilizando redes neurais convolucionais para que dada uma imagem de ultrassonografia pulmonar como entrada para os modelos treinados, tais modelos detectem se existem ou não a presença de artefatos de linha B. Assim, diante dos resultados promissores desta pesquisa, foi adicionada, neste trabalho, a tarefa de localização e segmentação dos artefatos de linha B nas imagens.

Neste trabalho, foi realizado uma comparação do desempenho das arquiteturas internas do DeepLabV3+ na tarefa de segmentação de artefatos de linha B em imagens de ultrassonografia pulmonar de pacientes diagnosticados com alguma doença pulmonar. Para isso, foram realizadas as marcações dos artefatos de linha B nas imagens de LUS, em seguida, foram treinados três modelos de aprendizagem profunda (Resnet-18, Resnet-50 e Exception) e, ao final, o desempenho das arquiteturas utilizadas foi comparado.

Este artigo está organizado da seguinte forma: A seção II apresenta a arquitetura utilizada. A seção III-A apresenta como os dados foram obtidos. Na seção III-B está detalhado como o treinamento dos modelos foram realizados e as ferramentas envolvidas. A seção III-B aborda sobre os experimentos. A seção IV apresenta os resultados obtidos. Na seção V estão disponíveis alguns pontos limitadores que foram encontrados durante a realização da pesquisa. Por fim, a seção VI apresenta as conclusões e as discussões.

2 ARQUITETURAS DAS REDES NEURAS UTILIZADAS PARA SEGMENTAÇÃO DE LINHA-B

Nesta pesquisa, foi realizado o treinamento de modelos de segmentação semântica, tal que, dada uma imagem de ultrassonografia pulmonar o interesse está na imagem de saída contendo a segmentação de artefatos de linha B, uma vez que esta se correlaciona com algum tipo de doença. Para isso, foi utilizado o DeepLabV3+ para comparar diversas arquiteturas no processo de segmentação dos artefatos de linha B.

Em 2018 foi proposto em [18] o modelo chamado *DeepLabv3+*, que estende o *DeepLabv3* criado em [19]. Foi estudado em [18] dois tipos de redes neurais, as que usam o módulo de agrupamento de pirâmide espacial que captura informações contextuais e as que usam a estrutura codificador-decodificador para segmentação semântica que é capaz de obter limites de objetos, desta forma identificando de forma precisa a região do objeto em relação ao fundo da imagem. Essas estruturas são usadas em redes neurais profundas para tarefas de segmentação semântica.

A Fig. 2 mostra a arquitetura básica de uma rede neural com segmentação semântica. Para o caso do *DeepLabV3+* ao receber uma imagem como entrada, a rede neural profunda realizará convolução *Atrous* ou convolução dilatada. Com isso, é possível extrair mapas de características mais densos sem a necessidade de realizar operações de *downsampling* e *upsampling*, isso é equivalente a inserir furos ('trous' em francês) entre os pesos dos filtros.

O módulo codificador(encoder) extrai informações semânticas e contextuais relevantes reduzindo gradualmente o mapa de características. Esse processo é feito aplicando a convolução *Atrous* em várias escalas enquanto o decodificador(decoder) recupera informações espaciais. Em seguida, o mapa de uma resolução espacial é redimensionado para a resolução espacial de entrada (antes da camada totalmente conectada). Assim, a imagem segmentada a nível de pixel é obtida como saída.

No estudo apresentado em [18] o modelo “DeepLabv3+” mostrou ser eficaz, sendo usado para codificar a rica informação contextual e com um módulo decodificador eficaz sendo adotado para recuperar os limites do objeto, desta forma, estabelecendo um novo estado da arte para a área de segmentação semântica e vem sendo amplamente utilizada em diversas aplicações. Assim, neste trabalho foram treinados três arquiteturas baseadas no modelo de segmentação semântica DeepLabV3+, foram elas: Resnet-18 [20], Resnet-50 [20] e Exception [21].

3 DADOS, MATERIAIS E EXPERIMENTOS

3.1 Dados

As imagens utilizadas neste trabalho foram disponibilizadas do projeto ICLUS¹ (Italy Covid-19 Lung Ultrasound) na qual disponibilizam um banco de imagens internacional que permite o envio de vídeos ou imagem (Raio-X, ultrassonografia e Tomografia computadorizada) de pacientes diagnosticados com Covid-19. A disponibilização deste banco de imagens, segundo os idealizadores do projeto ICLUS, foi feita para acelerar o desenvolvimento de novas técnicas e algoritmos que auxiliem no reconhecimento de Covid-19, e também visa fomentar o desenvolvimento de programas de telemedicina e processamento de imagens médicas [6].

Este banco de imagens foi obtido de diferentes clínicas (BresciaMed, Brescia, Italy, Valle del Serchio General Hospital, Lucca, Italy, Fondazione Policlinico Universitario A. Gemelli IRCCS, Rome, Italy, Fondazione Policlinico Universitario San Matteo IRCCS, Pavia, Italy, Tione General Hospital, Tione (TN), Italy) e na obtenção das imagens foram utilizadas diversos tipos de sondas de ultrassom (Mindray DC-70 Exp, Esaote MyLabAlpha, Toshiba Aplio XV, WiFi Ultrasound Probes - ATL). As imagens foram obtidas de 35 pacientes que foram diagnosticados com Covid-19.

Ao total, foram disponibilizados 60 vídeos de pessoas diagnosticadas com Covid-19. Após a obtenção dos vídeos, forma selecionados somente os que foram capturados por sondas convexas e que haviam presença nítida de linhas B. Em seguida, foi extraído alguns *frames* desses vídeos para aplicação deste estudo. Desta forma, foi obtido um total de 500 imagens de ultrassonografia para estudo exploratório.

3.2 Materiais e Detalhes da Implementação

Os modelos propostos foram treinados e implementados utilizando as bibliotecas no MATLAB. O algoritmo otimizador de treinamento SGDM (Stochastic Gradient Descent with momentum) padrão foi usado para a otimização da rede com a taxa de aprendizado definido para 0,01. O tamanho de lote foi de 30. Para a fase treinamento, foi realizado uma transformação polar das 500 imagens obtidas, para

isso, obteve-se os ângulos de corte (Fig. 3a), em seguida foi aplicada a transformação polar (Fig. 3b), seguido da marcação dos artefatos presentes nas imagens (Fig. 3c) e por fim foi realizada a geração das máscaras que foram utilizadas como entrada para o treinamento dos modelos (Fig. 3d). Desta forma, foram obtidas as marcações dos artefatos de linha B presentes em todas as imagens selecionadas.




Figura 3: Pré-processamento das Imagens para Treinamento

Das imagens obtidas e marcadas foram utilizadas 80% para treinamento e 20% para teste. O treinamento das arquiteturas foi realizado em 30 épocas.

Os experimentos foram realizados em um computador com sistema operacional Windows 10 (64-bit) com um processador AMD Ryzen 7 3700X 8-Core de 3.59 GHz, 16GB (GigaBytes) de RAM e uma placa de vídeo GeForce GTX 1050 Ti.

Além disso, foram utilizadas diversas ferramentas do MATLAB² como por exemplo o *Image Labeler*³, e funções já implementadas no MATLAB. A linguagem de programação foi a própria do Matlab, essa linguagem também é conhecida como M-código ou simplesmente M.

3.3 Validação do Experimento

Como métrica de avaliação para a tarefa de segmentação foi utilizada a métrica clássica Intersecção sobre União (IoU) das regiões previstas pelos modelos e os marcados pelo autor. Esse método de avaliação também conhecido como Similaridade de Jaccard permite indicar o quanto dois conjuntos são similares, considerando os seus

¹<https://covid19.disi.unitn.it/iclusdb>

²<https://www.mathworks.com/products/matlab.html>

³<https://www.mathworks.com/help/vision/ref/imagelabeler-app.html>




Figura 2: Arquitetura básica de uma S-CNN

elementos componentes. A similaridade de Jaccard é dada a partir da intersecção de dois conjuntos ($A \cap B$) dividido pela união desses dois conjuntos ($A \cup B$), como mostra a Fig. 4:

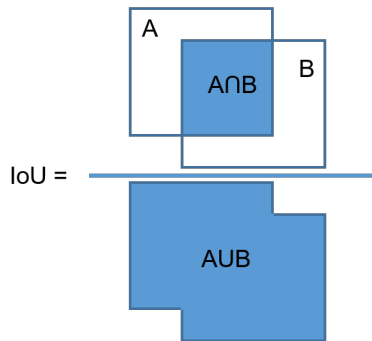


Figura 4: Ilustração da Similaridade de Jaccard

Em outras palavras, a similaridade de Jaccard se trata da intersecção da segmentação inferida e a máscara fundamental, dividida pela união. A equação que formaliza a similaridade Jaccard apresentada na Eq. 1.

$$IoU = \frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|} \quad (1)$$

Também foi utilizada a acurácia, precisão e sensibilidade como métricas complementares de avaliação. Desta forma, relatou-se a porcentagem de *pixels* na imagem que foram classificados corretamente.

Ao considerar a precisão de pixel para a segmentação dos artefatos de linha B, avalia-se, essencialmente, a máscara binária resultante; um **verdadeiro positivo** representa um pixel que está corretamente previsto para pertencer ao artefato de linha B (de acordo com a máscara de destino) enquanto um **verdadeiro negativo** representa um pixel que é corretamente identificado como não pertencente à classe dada. Por outro lado, um **falso positivo** representa um pixel que está incorretamente previsto para pertencer ao artefato de linha B (de acordo com a máscara de destino) enquanto

um **falso negativo** representa um pixel que é incorretamente identificado como não pertencente à classe dada.

Foi calculada a sensibilidade para descrever efetivamente a completude das previsões positivas dos *pixels* classificados pelos modelos em relação aos *pixels* de destino (máscara).

Desta forma, foi calculada a acurácia, representada na Eq. 2, a precisão, representada pela Eq. 3 e a sensibilidade representado pela Eq. 4. Sendo, vp os verdadeiros positivos, vn os verdadeiros negativos, fp os falsos positivos e fn os falsos negativos.

$$Acuracia = \frac{(vp + vn)}{(vp + fp + vn + fn)} \quad (2)$$

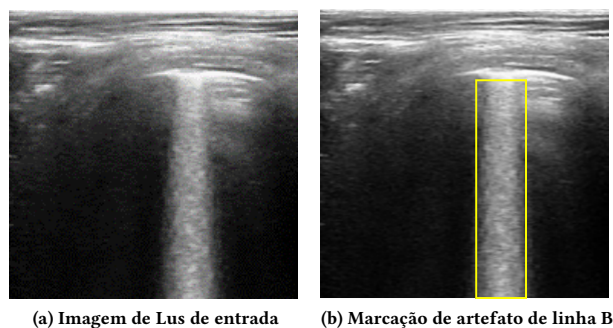
$$Precisao = \frac{vp}{vp + fp} \quad (3)$$

$$Sensibilidade = \frac{vp}{vp + fn} \quad (4)$$

Foi utilizada a similaridade de Jaccard, precisão, acurácia e sensibilidade para comparação entre os três modelos de arquiteturas treinados: Resnet-18, Resnet-50 e Exception.

4 RESULTADOS E DISCUSSÕES

A Fig. 5 mostra um exemplo ilustrativo do resultado da segmentação semântica aplicada a uma imagem de ultrassonografia pulmonar, juntamente com a sua respectiva marcação. Neste exemplo, foi utilizada a arquitetura Resnet-18 do DeepLabV3++. Este modelo recebe como entrada imagens de ultrassonografia pulmonar (Fig. 5a) e realiza a segmentação da região onde supostamente existe artefatos de linha B (Fig. 6a), assim, pode-se comparar a marcação desejada (Fig. 5b) com a região predita pelo modelo (Fig. 6a). Neste caso, a acurácia foi de 95.11% e a precisão de 75,09%. Por outro lado, Nota-se que, as regiões segmentadas pelo modelo tendem a ser mais flexíveis que as máscaras de entrada. Isso mostra que, algumas regiões que o modelo segmentou aparentemente como falso-positivo pode sim ser considerado como parte do artefato (dado o grau de profundidade do modelo da rede, ela tende a segmentar mais detalhes dos artefatos de linha B), entretanto não foi marcado como tal no processo de marcação dos artefatos.



(a) Imagem de Lus de entrada

(b) Marcação de artefato de linha B

Figura 5: Exemplo de entrada para o teste dos modelos. a) Imagem de entrada b) Artefato de linha B marcado com caixa delimitadora



(a) Segmentação semântica

(b) Região segmentada da imagem de entrada

Figura 6: Exemplo de segmentação semântica. a) Resultado da segmentação semântica, onde é gerado uma máscara b) A Visualização da região segmentada sobre a imagem de entrada

Desta forma, a avaliação do conjunto de teste, junto com as marcações, pode se mostrar inadequado no processo avaliativo dos modelos treinados, uma vez que a incerteza de marcação ou não marcação é uma tarefa que envolve diretamente a decisão envolvidos nesta tarefa, assim, influenciando diretamente nos resultados. Inúmeras discussões sobre esse desafio podem ser geradas, no entanto, neste trabalho foi utilizada a mesma base de imagens e marcações para avaliar os modelos, permitindo assim uma avaliação justa entre os modelos.

Os resultados para nosso conjunto de imagens selecionadas são apresentados na Fig. 7 onde mostra os resultados de cada modelo na tentativa de segmentar linha-B presentes nas imagens testadas. Observa-se que para a Resnet-18 a mediana obtida da similaridade de Jaccard obtida foi de 79.34% enquanto para a Resnet-50 foi de 79.27%, ou seja, não houve diferença significativa entre o desempenho desses dois modelos testados, enquanto a mediana da similaridade de Jaccard para a Xception foi de 76.06% obtendo assim a pior performance dentre os três modelos.

Por outro lado, analisando os resultados mínimos e máximos dos modelos treinados, pode-se observar que a Resnet-50 atingiu

resultados mais satisfatórios que os demais modelos, obtendo maior e menor similaridades obtidas de 96.74% e 38.51%, respectivamente. No entanto, a distribuição dos valores indicam uma consistência menor que a Resnet-18 que obteve maior e menor similaridades de 95.37% e 43.95%, respectivamente. No caso da Xception a maior similaridade obtida foi de 90.16% e a menor de 36.37%. Por fim, para todos modelos treinados houveram resultados atípicos.




Figura 7: Representação da similaridade de Jaccard obtida para os três modelos treinados para a segmentação de linha B

A Fig. 8 apresenta os resultados da precisão dos modelos treinados. A mediana da precisão obtida para a Resnet-18, Resnet-50 e Exception foi de 92.32%, 90.16% e 88.60%, respectivamente. O modelo baseado na **Resnet-18** apresentou uma precisão maior em relação aos demais modelos, indicando assim que esta arquitetura tende ser mais satisfatória na segmentação de artefatos de linha B. Em contraste, o modelo baseado na arquitetura Exception apresentou menor precisão que todos demais modelos.

Nota-se que, não há uma diferença significativa na precisão entre a Resnet-18 e a Resnet-50 segundo o comportamento apresentado pelo gráfico de caixas (*boxplot*).

A Fig. 9 apresenta a acurácia dos modelos treinados. A mediana da acurácia obtida para a Resnet-18, Resnet-50 e Exception foi de 95.94%, 96.07% e 94.95%, respectivamente. Neste caso, a **Resnet-50** apresentou uma acurácia melhor que os demais modelos.

Por fim, a Fig. 10 mostra a sensibilidade dos modelos treinados. A mediana da sensibilidade obtida para a Resnet-18, Resnet-50 e Exception foi de 90.43%, 91.39% e 87.23%, respectivamente. A **Resnet-50** obteve maior sensibilidade dentre os modelos treinados, indicando assim que, esta arquitetura se mostra satisfatória na classificação das regiões onde os artefatos de linha B estão presentes nas imagens de LUS. E, novamente o modelo baseado na arquitetura Exception apresentou menor sensibilidade que os demais modelos.

Diante do exposto, pode-se notar que os modelos treinados baseados nas arquiteturas Resnet-18 e Resnet-50 apresentam resultados quase idênticos, entretanto, foi possível notar que o modelo treinado utilizando a arquitetura Exception obteve resultados inferiores na




Figura 8: Gráfico de Caixas da precisão dos modelos treinados para a segmentação de artefatos de linha B




Figura 10: Gráfico de Caixas da sensibilidade dos modelos treinados para a segmentação de artefatos de linha B




Figura 9: Gráfico de Caixas da acurácia dos modelos treinados para a segmentação de artefatos de linha B

maioria das métricas calculadas, assim tornando-se o modelo com o desempenho inferior aos modelos utilizando as demais arquiteturas, como mostra a Tab. 1.

Tabela 1: Resultados dos modelos de segmentação e detecção das linhas B no banco de imagens ICLUS

Arquitetura	IoU	Prec.	Sens.	Acurácia
Resnet-18	79.35%	92.33%	90.44%	95.95%
Resnet-50	79.27%	90.16%	91.34%	96.08%
Exception	76.06%	88.60%	87.23%	94.96%

Finalmente, com esses resultados pode-se ter uma visão sobre o desempenho dos modelos treinados baseados nas arquiteturas que

utilizam segmentação semântica aplicados ao processamento de imagens de ultrassonografia pulmonar utilizando o DeepLabV3+. De forma geral, também é possível observar que a segmentação semântica possui grande potencial quando aplicada no cenário de imagens médicas de LUS podendo ser utilizada como meio alternativo para localizar automaticamente os artefatos de linha B e melhorar a precisão clínica nos diagnósticos de pessoas com anomalias pulmonares.

5 LIMITAÇÕES

Para o treinamento de modelos profundos de segmentação é importante que o conjunto de dados seja grande e mais heterogêneo. Entretanto, não existem bancos de imagens de ultrassonografia pulmonar disponíveis publicamente para a tarefa de segmentação de artefatos de linhas B. Nesse trabalho, foram selecionadas algumas imagens do banco de imagens ICLUS para estudo exploratório e, por conseguinte, a quantidade de imagens utilizada foi baixa e pouco diversificada. Além disso, os vídeos foram capturados dos pacientes que obtinham uma condição patológica mais grave, sendo mais notória a presença de artefatos nas imagens adquiridas, além de todos serem da Itália.

Por fim, vale destacar que, as marcações foram realizadas pelo autor deste trabalho e foram utilizadas apenas para estudo exploratório. Essas marcações seguiram o padrão apresentado por [4], sendo adicionado a etapa de transformação polar das imagens para a obtenção dos artefatos de linha B no formato vertical nas imagens. Assim, o processo de marcação foi realizado utilizando o formato retangular, como mostrado na seção III-B. Uma consequência deste procedimento foi a influência direta nos resultados, dado que os modelos realizaram a segmentação com um nível de detalhes maiores que as marcações originais.

6 CONSIDERAÇÕES FINAIS

De maneira geral, pode-se notar que avaliar imagens de ultrassonografia e identificar artefatos de linha B é muito útil no processo de

diagnóstico do paciente, e uma ferramenta ou método que facilite e auxilie uma avaliação clínica tem sua importância.

Neste trabalho, foi apresentado uma forma de transformar imagens de ultrassonografia pulmonar no formato convexo para o linear para facilitar na identificação e marcação de artefatos de linhas B nas imagens. Também, foi apresentado uma comparação de modelos de arquiteturas de redes neurais profundos baseados na segmentação semântica capazes de segmentar artefatos de linhas B em imagens de ultrassonografia pulmonar utilizando o DeepLabV3+. As arquiteturas treinadas foram a Resnet-18, Resnet-50 e Xception. Estas arquiteturas treinadas nos permitiram capturar informações espaciais da localização dos artefatos de linha B presentes nas imagens.

Dos modelos treinados o que mais obteve destaque baseado na similaridade de Jaccard foi o modelo treinado utilizando a arquitetura Resnet-18. O modelo treinado utilizando a arquitetura Resnet-50 apresentou semelhantes ao modelos que utilizou a arquitetura Resnet-18, e até mesmo apresentou melhor acurácia e sensibilidade em relação aos demais modelos. Ficou notório que a Exception foi a arquitetura que obteve o menor desempenho dentre as arquiteturas utilizadas. No entanto, vale ressaltar que esses resultados podem sofrer alterações a depender de diversos fatores como a quantidade de imagens, os parâmetros para treinamento dos modelos de aprendizado profundo ou até mesmo das marcações dos artefatos presentes nas imagens.

Portanto, o desempenho dos modelos avaliados neste trabalho mostraram uma capacidade de localizar artefatos de linha B obtendo similaridades de até 96.74%, precisão de até 100%, acurácia de até 99.12% e sensibilidade de até 100%, como mostrado na seção IV. Estes resultados demonstram a eficiência da segmentação semântica em imagens médicas de ultrassonografia pulmonar se mostrando assim um método consistente indicado para segmentação de artefato de linhas B.

Para trabalhos futuros, inclui-se a possibilidade de alteração dos parâmetros de treinamento, e a adição de mais artefatos e imagens. Além da comparação entre os algoritmos de otimização de aprendizado. Também deve ser considerado a possibilidade da adição de outras arquiteturas, bem como a Resnet101, pois em geral apresentam bom desempenho em diversas aplicações.

Por fim, os resultados obtidos apresentaram uma comparação entre três arquiteturas diferentes que usam segmentação semântica para a detecção de artefatos de linha B permitindo assim não só uma comparação intra-arquiteturas mas sobre os avanços e a potencialidade de utilizar segmentação semântica em imagens médicas de ultrassonografia pulmonar. Assim, pode-se afirmar que, método demonstrado pode ser utilizado como uma ferramenta de auxílio no diagnóstico clínico de pacientes com doenças pulmonares, especialmente para usuários que não possuem tanta experiência com ultrassom.

7 AGRADECIMENTOS

Esta pesquisa foi realizada com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES). Este trabalho também teve apoio do projeto de Telemedicina e do projeto de Pesquisa Aplicada em Visão Computacional e Inteligência Computacional da Motorola (PAVIC).

REFERÊNCIAS

- [1] Ruud JG van Sloun and Libertario Demi. Localizing b-lines in lung ultrasonography by weakly supervised deep learning, in-vivo results. *IEEE journal of biomedical and health informatics*, 24(4):957–964, 2019.
- [2] Ramin Moshavegh, Kristoffer Lindskov Hansen, Hasse Møller-Sørensen, Michael Bachmann Nielsen, and Jørgen Arendt Jensen. Automatic detection of b-lines in *in vivo* lung ultrasound. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 66(2):309–317, 2019. doi: 10.1109/TUFFC.2018.2885955.
- [3] Rodrigo Ribeiro de Oliveira, Thiago Potrich Rodrigues, Paulo Savoia Dias da Silva, Andrea Cavallanti Gomes, and Maria Cristina Chammas. Lung ultrasound: an additional tool in COVID-19. *Radiologia Brasileira*, 53:241 – 251, 08 2020. ISSN 0100-3984. URL http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-39842020000400241&nrm=iso.
- [4] Subhankar Roy, Willi Menapace, Sebastiaan Oei, Ben Luijten, Enrico Fini, Cristiano Saltori, Iris Huijben, Nishith Chennakeshava, Federico Mento, Alessandro Sentelli, Emanuele Peschiera, Riccardo Trevisan, Giovanni Maschietto, Elena Torri, Riccardo Inchingolo, Andrea Smargiassi, Gino Soldati, Paolo Rota, Andrea Passerini, Ruud J. G. van Sloun, Elisa Ricci, and Libertario Demi. Deep learning for classification and localization of COVID-19 markers in point-of-care lung ultrasound. *IEEE Transactions on Medical Imaging*, 39(8):2676–2687, aug 2020. doi: 10.1109/tmi.2020.2994459. URL <https://doi.org/10.1109/2Ftmi.2020.2994459>.
- [5] Oktay Karakus, Nantheera Anantrasirichai, Amazigh Aguersif, Stein Silva, Adrian Basarab, and Alin Achim. Detection of line artifacts in lung ultrasound images of COVID-19 patients via nonconvex regularization. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 67(11):2218–2229, nov 2020. doi: 10.1109/tuffc.2020.3016092. URL <https://doi.org/10.1109/2Ftuffc.2020.3016092>.
- [6] Gino Soldati, Andrea Smargiassi, Riccardo Inchingolo, Danilo Buonsenso, Tiziano Perrone, Domenica Federica Briganti, Stefano Perlini, Elena Torri, Alberto Mariani, Elisa Eleonora Mossolani, Francesco Tursi, Federico Mento, and Libertario Demi. Proposal for international standardization of the use of lung ultrasound for patients with covid-19. *Journal of Ultrasound in Medicine*, 39(7):1413–1419, April 2020. doi: 10.1002/jum.15285. URL <https://doi.org/10.1002/jum.15285>.
- [7] Hui Che, Jared Radbel, Jag Sunderram, John L Noshier, Vishal M Patel, and Ilker Hacihaliloglu. Multi-feature multi-scale cnn-derived covid-19 classification from lung ultrasound data. *arXiv preprint arXiv:2102.11942*, 2021.
- [8] Federico Mento and Libertario Demi. Effect of imaging parameters on the visualization of lung ultrasound b-line artifacts. In *2020 IEEE International Ultrasonics Symposium (IUS)*. IEEE, sep 2020. doi: 10.1109/ius46767.2020.9251818. URL <https://doi.org/10.1109/2Fius46767.2020.9251818>.
- [9] Jannis Born, Nina Wiedemann, Manuel Cossio, Charlotte Buhre, Gabriel Brändle, Konstantin Leidermann, Julie Goulet, Avinash Aujayeb, Michael Moor, Bastian Rieck, and Karsten Borgwardt. Accelerating detection of lung pathologies with explainable ultrasound image analysis. *Applied Sciences*, 11(2), 2021. ISSN 2076-3417. doi: 10.3390/app11020672. URL <https://www.mdpi.com/2076-3417/11/2/672>.
- [10] Gino Soldati, Marcello Demi, and Libertario Demi. Ultrasound patterns of pulmonary edema. *Annals of Translational Medicine*, 7(S1):S16–S16, mar 2019. doi: 10.21037/atm.2019.01.49. URL <https://doi.org/10.21037/2Fatm.2019.01.49>.
- [11] Hamideh Kerdegari, Phung Tran Huy Nhat, Angela McBride, VITAL Consortium, Reza Razavi, Nguyen Van Hao, Louise Thwaites, Sophie Yacoub, and Alberto Gomez. Automatic detection of b-lines in lung ultrasound videos from severe dengue patients. *arXiv preprint arXiv:2102.01059*, 2021.
- [12] Francesco Corradi, Claudia Brusasco, Antonella Vezzani, Gregorio Santori, Tullio Manca, Lorenzo Ball, Francesco Nicolini, Tiziano Gherli, and Vito Brusasco. Computer-aided quantitative ultrasonography for detection of pulmonary edema in mechanically ventilated cardiac surgery patients. *Chest*, 150(3):640–651, sep 2016. doi: 10.1016/j.chest.2016.04.013. URL <https://doi.org/10.1016/2Fj.chest.2016.04.013>.
- [13] Nantheera Anantrasirichai, Marco Allinovi, Wesley Hayes, and Alin Achim. Automatic b-line detection in paediatric lung ultrasound. In *2016 IEEE International Ultrasonics Symposium (IUS)*. IEEE, sep 2016. doi: 10.1109/ultsym.2016.7728620. URL <https://doi.org/10.1109/2Fultsym.2016.7728620>.
- [14] Nantheera Anantrasirichai, Marco Allinovi, Wesley Hayes, David Bull, and Alin Achim. Line detection in speckle images using radon transform and l1 regularization. In *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 6240–6244, 2017. doi: 10.1109/ICASSP.2017.7953356.
- [15] Nantheera Anantrasirichai, Wesley Hayes, Marco Allinovi, David Bull, and Alin Achim. Line detection as an inverse problem: Application to lung ultrasound imaging. *IEEE Transactions on Medical Imaging*, 36(10):2045–2056, oct 2017. doi: 10.1109/tmi.2017.2715880. URL <https://doi.org/10.1109/2Ftmi.2017.2715880>.
- [16] Laura J. Brattain, Brian A. Telfer, Andrew S. Liteplo, and Vicki E. Noble. Automated b-line scoring on thoracic sonography. *Journal of Ultrasound in Medicine*, 32(12):2185–2190, dec 2013. doi: 10.7863/ultra.32.12.2185. URL <https://doi.org/10.7863/2Fultra.32.12.2185>.
- [17] S. M. Mafalda and R. F. L. Chavez. Detection of the presence of artifacts of b-line in ultrasound image lung using cnn [publishing]. 2021.

XIV Computer on the Beach

30 de Março a 01 de Abril de 2023, Florianópolis, SC, Brasil

- [18] Liang-Chieh Chen, Yukun Zhu, George Papandreou, Florian Schroff, and Hartwig Adam. Encoder-decoder with atrous separable convolution for semantic image segmentation, 2018. URL <https://arxiv.org/abs/1802.02611>.
- [19] Liang-Chieh Chen, George Papandreou, Florian Schroff, and Hartwig Adam. Rethinking atrous convolution for semantic image segmentation, 2017. URL <https://arxiv.org/abs/1706.05587>.
- [20] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 770–778, 2016. doi: 10.1109/CVPR.2016.90.
- [21] François Chollet. Xception: Deep learning with depthwise separable convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 1800–1807, 2017.