

Segmentação de Imagens Infravermelhas Para Detecção do Câncer de Mama Utilizando U-NET CNN

Matheus de Freitas Oliveira Baffa¹, Alessandra Martins Coelho², Aura Conci³

¹Departamento de Computação e Matemática
Universidade de São Paulo (USP)
Ribeirão Preto, SP – Brasil

²Departamento Acadêmico da Ciência da Computação
Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de
Minas Gerais (IF SudesteMG)
Rio Pomba, MG – Brasil

³Instituto de Computação
Universidade Federal Fluminense (UFF)
Niterói, RJ – Brasil

mbaffa@usp.br, alessandra.coelho@ifsudestemg.edu.br, aconci@ic.uff.br

Abstract. *Breast cancer is the leading type of cancer among women. According to the World Cancer Research Fund, in 2018, over 2 million new cases were detected around the world. Despite its high occurrence, early detection provides a better prognosis and helps increase the patient's survival. Significant advances in screening techniques, such as infrared imaging, have provided a cheap and less invasive way to detect the disease. Besides, computational tools can be used to assist doctors to provide a better diagnosis. Thus, this paper presents a segmentation method based on U-Net Convolutional Neural Networks. In contrast to state-of-art, machine learning approaches have shown to be efficient for the region of interest segmentation, reaching an accuracy of 98.24% and an Intersection-Over-Union of 94.38%. The use of this segmentation method may be very useful for classification tasks, once the region of interest is well delimited for feature extraction.*

Resumo. *O câncer de mama é o principal tipo de câncer entre as mulheres. De acordo com o World Cancer Research Fund, em 2018, mais de 2 milhões de novos casos foram detectados em todo o mundo. Apesar de sua alta ocorrência, a detecção precoce proporciona um melhor prognóstico e auxilia no aumento da sobrevida do paciente oncológico. Avanços significativos nas técnicas de rastreamento, como as imagens infravermelhas, forneceram uma maneira barata e menos invasiva forma de detectar a doença. Além disso, ferramentas computacionais podem ser utilizadas para auxiliar os médicos a fornecerem um melhor diagnóstico. Assim, este artigo apresenta um método de segmentação baseado em Redes Neurais Convolucionais U-Net. Em contraste com o estado da arte, as abordagens de aprendizado de máquina têm se mostrado eficientes para a segmentação da região de interesse deste trabalho, atingindo uma acurácia de 98,24% e uma Intersecção-Sobre-União de 94,38%. O uso deste método de segmentação pode ser muito útil para tarefas de classificação, uma vez que a região de interesse é bem delimitada para extração de características.*

1. Introdução

A Visão Computacional é uma área de pesquisa que relaciona técnicas de processamento e análise de imagens ao reconhecimento de padrões a partir da Inteligência Artificial. O objetivo da literatura nesse campo de pesquisa é interpretar e extrair novos conhecimentos sobre os elementos que compõem uma cena ou uma imagem digital [Conci et al. 2008].

Alinhado ao desenvolvimento de novas tecnologias, a Visão Computacional tem sido responsável pelo avanço de diferentes linhas de pesquisa. A área médica, por exemplo, tem utilizado técnicas de Visão Computacional para reconhecer padrões que permitem a identificação de pacientes infectados com COVID-19 [Ismael and Şengür 2021], na identificação de tumores cerebrais [Rehman et al. 2021] e na detecção do câncer de mama [Baffa and Lattari 2018].

No âmbito do diagnóstico do câncer de mama, as imagens médicas possuem um papel fundamental na detecção e no acompanhamento do tratamento do paciente. Os tipos de imagens mais utilizados na detecção do câncer de mama são a mamografia e a Ressonância Magnética [U.S. National Cancer Institute. 2021].

Caracterizado pelo crescimento acelerado e desordenado de células nas estruturas da mama, o câncer de mama é o tipo mais frequente entre as mulheres. O Instituto Nacional do Câncer (INCA), estimou para 2020 um total de 66.280 novos casos da doença no Brasil, com uma taxa de letalidade de aproximadamente 27% [Instituto Nacional do Cancer. 2021].

Para um melhor prognóstico da doença, é indispensável realizar a detecção precoce. Uma estimativa do Instituto Nacional de Saúde da Mulher, da Criança e do Adolescente (IFF/Fiocruz) mostrou que quando descoberto nos estágios iniciais, as chances de cura do câncer de mama podem chegar a 95% [IFF/Fiocruz. 2021].

A termografia, exame o qual é obtido uma imagem infravermelha representando a temperatura da superfície da pele, é um tipo de imagem emergente no diagnóstico do câncer de mama [Zuluaga-Gomez et al. 2019]. Além de requerer equipamentos mais baratos para sua obtenção, as imagens infravermelhas podem detectar tumores milimétricos, devido a natureza bioquímica dos tumores [Amalu et al. 2006].

A detecção do câncer de mama pela termografia é guiada pela análise da distribuição térmica por entre as mamas. É característico do corpo humano que, ao longo da superfície do corpo, a temperatura da pele seja similar por longos períodos de observação, sendo simétricos sob o eixo sagital [Gore and Xu 2003].

O desenvolvimento de sistemas de Visão Computacional pode auxiliar no processo de identificação e diagnóstico de exames. Estes sistemas, de forma inteligente detectam padrões que permitem distinguir exames provenientes de pacientes saudáveis e pacientes com tumor em alguma das estruturas que compõem as mamas. Os sistemas que auxiliam no diagnóstico médico são denominados Sistemas CADx (*Computer-Aided Diagnosis*).

Os Sistemas CADx, assim como os sistemas de Visão Computacional, são geralmente compostos por três etapas, sendo elas (i) a segmentação da região de interesse (*Region of Interest* - ROI), (ii) a construção de descritores e (iii) a detecção de padrões. A segmentação da ROI é uma etapa fundamental no processo de construção do sistema CADx, uma vez que permite o programa realizar uma análise da imagem apenas da região

onde provavelmente vá estar o tumor. Já a construção dos vetores descritores é realizada a partir da extração de características que permitem a identificação dos elementos que compõem a imagem. E por fim, a detecção de padrões é realizada utilizando técnicas de aprendizado de máquina, que aprende regras e cria modelos de classificação a partir do descritor criado na etapa anterior.

Desta forma, neste trabalho é apresentado um método de segmentação da ROI, compreendido no âmbito do diagnóstico do câncer de mama como a região externa das mamas, desde as pregas inframamárias ao pescoço. O método proposto neste trabalho implementa uma variação da U-Net, uma Rede Neural Convolutiva comumente utilizada na segmentação de lâminas de tecidos histológicos. A principal contribuição deste trabalho é o modelo de segmentação baseado em Redes Neurais Profundas.

Nas seções seguintes deste trabalho, serão abordadas as atuais soluções para o problema de segmentação de imagens infravermelhas da mama disponíveis na literatura (Seção II), bem como a descrição da base de dados (Seção III), a metodologia de segmentação utilizando as Redes Neurais Convolutivas (Seção IV), os experimentos e resultados obtidos pelo método proposto (Seção V) e, por fim, a conclusão (Seção VI).

2. Segmentação de Termografias na Literatura

A correta segmentação da ROI em termografias favorece uma extração de características mais eficiente, resultando em sistemas CADx com modelos de classificação mais precisos e eficazes. Tal problema de segmentação é abordado na literatura e tratado a partir do uso de técnicas convencionais de processamento de imagens. Nesta seção iremos abordar alguns destes trabalhos.

[Motta 2010] propôs em seu trabalho um método de segmentação da ROI utilizando uma sequência de técnicas de processamento de imagens. Dentre estas, o autor realiza a remoção do fundo utilizando limiarização de *Otsu*, bem como encontra o limite superior das axilas, remove os braços presentes na imagem e separa as mamas esquerda e direita utilizando técnicas como a morfologia matemática, a detecção de contornos de *Canny*, a transformada de *Hough* e limiarização com refinamento adaptativo. O autor obteve uma acurácia média de 96%, uma sensibilidade de 88% e uma especificidade de 99%, avaliando sob a base de dados DMR-UFF [Silva et al. 2014].

Posteriormente, [Marques 2012] descreve um método de segmentação, também utilizando técnicas de processamento de imagens, baseado na identificação dos limites superiores, inferiores e laterais. As principais ferramentas utilizadas pelo autor é a detecção de contornos, a limiarização, o crescimento de regiões e o ajuste de curvas por mínimo quadrado e *B-Splines*. O autor reporta uma acurácia média de 97%, uma sensibilidade de 97% e uma especificidade de 97%, por entre os experimentos realizados na base de dados DMR-UFF.

Em 2016, [Baffa et al. 2016] desenvolveram um método de segmentação baseado na técnica de limiarização por refinamento adaptativo. Neste trabalho os autores detectam as regiões externas do corpo da paciente, bem como a região inferior das mamas e, a partir do cálculo da área das pregas inframamárias, um valor de limiar é encontrado. A segmentação foi avaliada sob 283 imagens infravermelhas provenientes da base de dados DMR-UFF. Os autores reportaram uma acurácia média de 96%, entre os experimentos realizados, uma sensibilidade de 98% e uma especificidade de 95%.

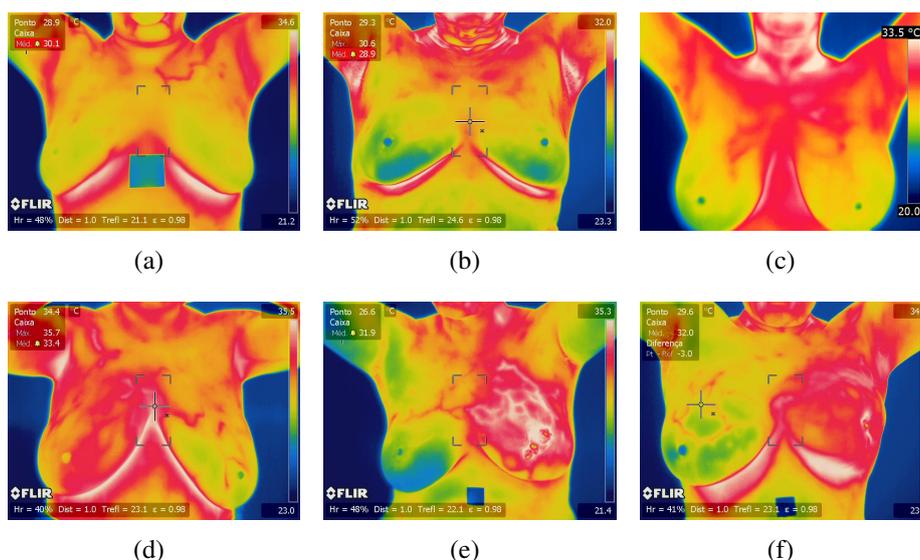
De maneira similar, [Marques et al. 2016] propôs o desenvolvimento de um método de segmentação baseado na aplicação de uma sequência de ferramentas de processamento de imagens. Nesta sequência, são utilizadas técnicas como limiarização, clusterização, detecção de bordas e refinamento. O método proposto pelos autores foi avaliado sobre 328 imagens infravermelhas provenientes da base de dados DMR-UFF. Os autores reportaram uma acurácia de 96% e uma sensibilidade de 97%.

Diferente das propostas supracitadas, [Melo et al. 2017] utilizou uma Rede Neural Convolutiva para realizar a segmentação da ROI em termografias. Neste trabalho, o autor desenvolve uma Rede Neural Convolutiva baseada na subarquitetura *Visual Geometric Group* (VGG-CNN). Para o treinamento e avaliação da Rede Neural, foram utilizadas 285 imagens provenientes da base de dados DMR-UFF. O método proposto pelos autores obteve uma taxa de acurácia média entre os experimentos de 95,61%, uma sensibilidade de 97,44% e uma especificidade de 94,01%.

3. Base de Imagens Infravermelhas da Mama

Para realizar o treinamento e avaliação do método proposto neste trabalho, foi utilizada uma base de imagens infravermelhas pública, desenvolvida pelo Grupo de Pesquisa *Visual Lab*, da Universidade Federal Fluminense. A base de dados *Database for Mastology Research* (DMR-UFF) [Silva et al. 2014] é composta por 283 imagens infravermelhas, provenientes de pacientes saudáveis e pacientes diagnosticados com câncer de mama. Além destas, uma segmentação manual também é disponibilizada no portal do grupo de pesquisa para fins de avaliação dos métodos de segmentação automática. A Figura 1 contém algumas das imagens encontradas nesta base de dados.

Figura 1. Termografias que compõem a base de dados DMR-UFF.



Fonte: [Silva et al. 2014].

Em (a), (b) e (c), alguns exemplos de termografias de pacientes saudáveis enquanto em (d), (e) e (f), exemplos de termografias de pacientes doentes.

4. Metodologia de Segmentação por U-Net

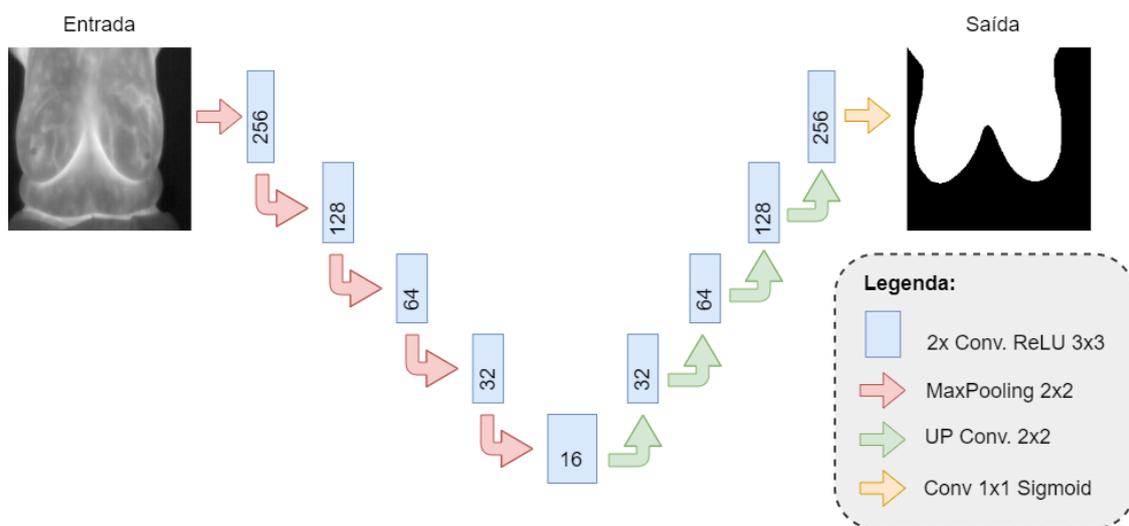
A U-Net é uma subarquitetura de Redes Neurais Convolucionais (*Convolutional Neural Network* – CNN) desenvolvida com o foco na solução de problemas de segmentação de imagens biomédicas, em especial imagens contendo tecidos histológico. Caracterizada pelo formato similar a curva de uma parábola, a U-Net combina camadas de convoluções seguidas por operações de *MaxPooling* e *Upsampling*. Estas operações são responsáveis por reduzir o espaço amostral da imagem, caracterizando nas representações da arquitetura da rede como a 'descida' de uma parábola (*MaxPooling*), e em sequência, fazendo o caminho inverso, é realizado uma ampliação do espaço amostral, utilizando técnicas de vizinhos mais próximos (*Upsampling*) [Ronneberger et al. 2015].

Devido a sua alta eficiência, robustez em construir máscaras de segmentação e baixo tempo de treinamento e inferência, neste trabalho é proposto uma transposição das aplicações biomédicas da U-Net, para a construção de um algoritmo segmentador automático, aplicado à imagens médicas.

Para fins de replicabilidade, a arquitetura da U-Net proposta neste trabalho possui a seguinte configuração. Uma camada de entrada, o qual recebe uma imagem infravermelha da mama de 256×256 pixels, em escala de tons de cinza, e sua respectiva segmentação manual binária, ou *groundtruth*. São utilizadas 12 camadas de convolução, sendo seis para redução do espaço amostral utilizando a operação de *MaxPooling* com tamanho 2×2 e mais seis camadas de *Upsampling*, também de tamanho 2×2 . As camadas de convolução utilizam a função de ativação *Rectifier Linear Unit* (ReLU) e extraem respectivamente 256, 128, 64, 32 e 16 filtros (*MaxPooling*) e 16, 32, 64, 128, 256 filtros (*Upsampling*), todos de tamanho 3×3 . E por fim, a camada de saída é composta por uma camada de convolução 1×1 cuja função de ativação utilizada é a sigmoid.

O conjunto de hiperparâmetros utilizado para o treinamento foi definido empiricamente, com objetivo de maximizar a métrica *Intersection-Over-Union* (IOU). A Figura 2 contém um esquema gráfico representando os hiperparâmetros utilizados, bem como permite a visualização da estrutura da U-Net.

Figura 2. Customização da U-Net CNN proposta neste trabalho.



Fonte: autor

5. Experimentos e Resultados

Para o desenvolvimento do método, foi utilizado um computador com um processador AMD Ryzen 7 1700, 16 GB de memória RAM, uma placa de vídeo NVIDIA GTX 1060 6GB e sistema operacional *Windows 10 Pro*. A implementação da U-Net foi realizada utilizando a plataforma Anaconda 3, com *Python 3.7*, *Tensorflow 2.1* e *Keras 2.3*.

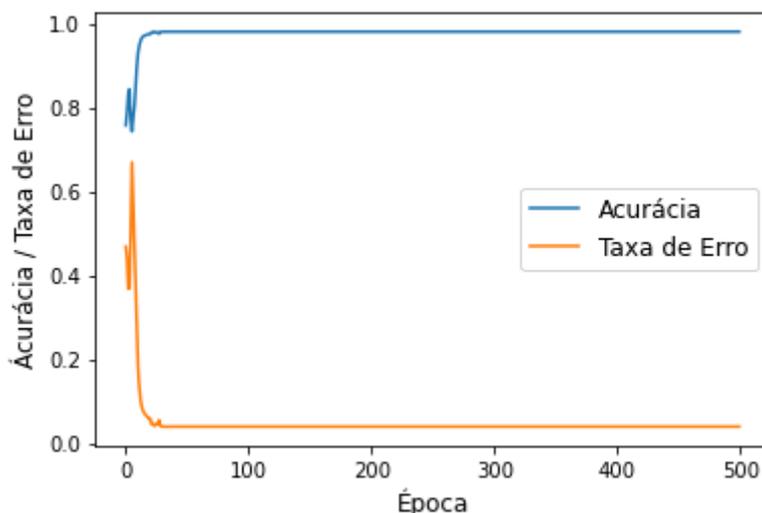
Os experimentos para validação do treinamento foram realizados seguindo o protocolo de experimentação *Holdout Cross-Validation*. Neste protocolo, parte da base de dados é utilizada para o treinamento, enquanto uma outra porção é exclusivamente utilizada para validação de forma que, as imagens utilizadas no treinamento sejam diferentes das imagens da validação. Assim, 70% da base de dados foi utilizada para o treinamento da Rede Neural e 30% foi utilizada para validação.

Para avaliar quantitativamente o método, foram utilizadas quatro métricas, sendo elas a acurácia, a área de interseção-sobre-união (*Intersection-Over-Union – IOU*), a precisão e a revocação. Compreendida como uma métrica fundamental para avaliação de metodologias de segmentação, a IOU avalia a sobreposição entre máscaras de segmentação, informando a eficácia da segmentação semântica das imagens. Nesse trabalho, o processo de treinamento e experimentação buscou maximizar os valores de IOU obtidos. A IOU pode ser obtida através do cálculo Equação 1, a seguir:

$$IOU = \frac{\text{Sobreposição}}{\text{União}} \quad (1)$$

De modo geral, seguindo a arquitetura de U-Net proposta, o método convergiu ao ótimo por volta da época 30, mantendo-se estável por todo o experimento. O método proposto neste trabalho obteve uma taxa de acurácia média de 98,38% e uma baixa taxa de erro. A Figura 3 contém um gráfico com a validação do modelo de segmentação criado pela U-Net ao longo das épocas.

Figura 3. Resultados obtidos em termos de acurácia e taxa de perda por época.

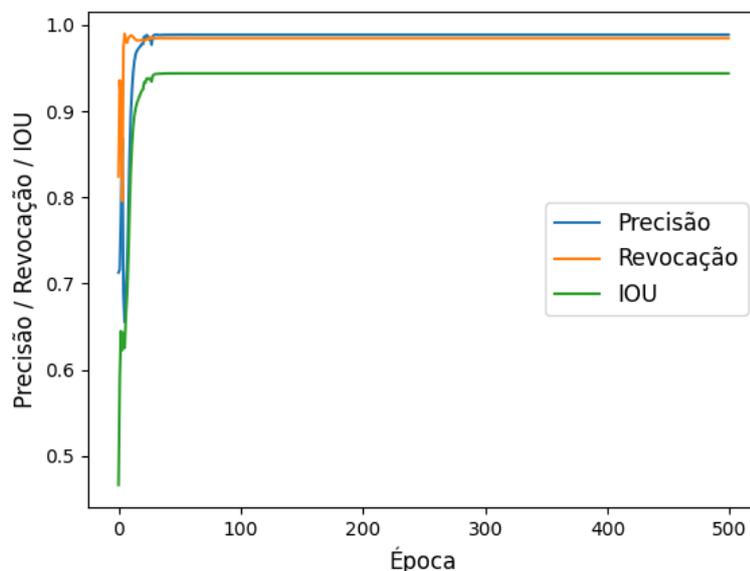


Fonte: autor.

Além da acurácia, o método proposto também obteve resultados excelentes em

função da métrica maximizada IOU, bem como a precisão e a revocação, atingindo uma IOU média de 94,38%, uma precisão média de 98,86% e uma revocação de 98,46%. A Figura 4 contém um gráfico ilustrando a validação do modelo de segmentação em termos das métricas apresentadas.

Figura 4. Resultados obtidos em termos de precisão, revocação e IOU por época.



Fonte: autor.

Os resultados visuais do processo de segmentação podem ser vistos na Figura 5. Nesta Figura são apresentadas algumas imagens originais da base de dados DMR-UFF, em escala de tons de cinza (Figura 5 (a)), bem como seu respectivo *groundtruth* (Figura 5 (b)) desenvolvido por um especialista e disponibilizado para fins de comparação, e a máscara de segmentação automática criada a partir do método proposto (Figura 5 (c)).

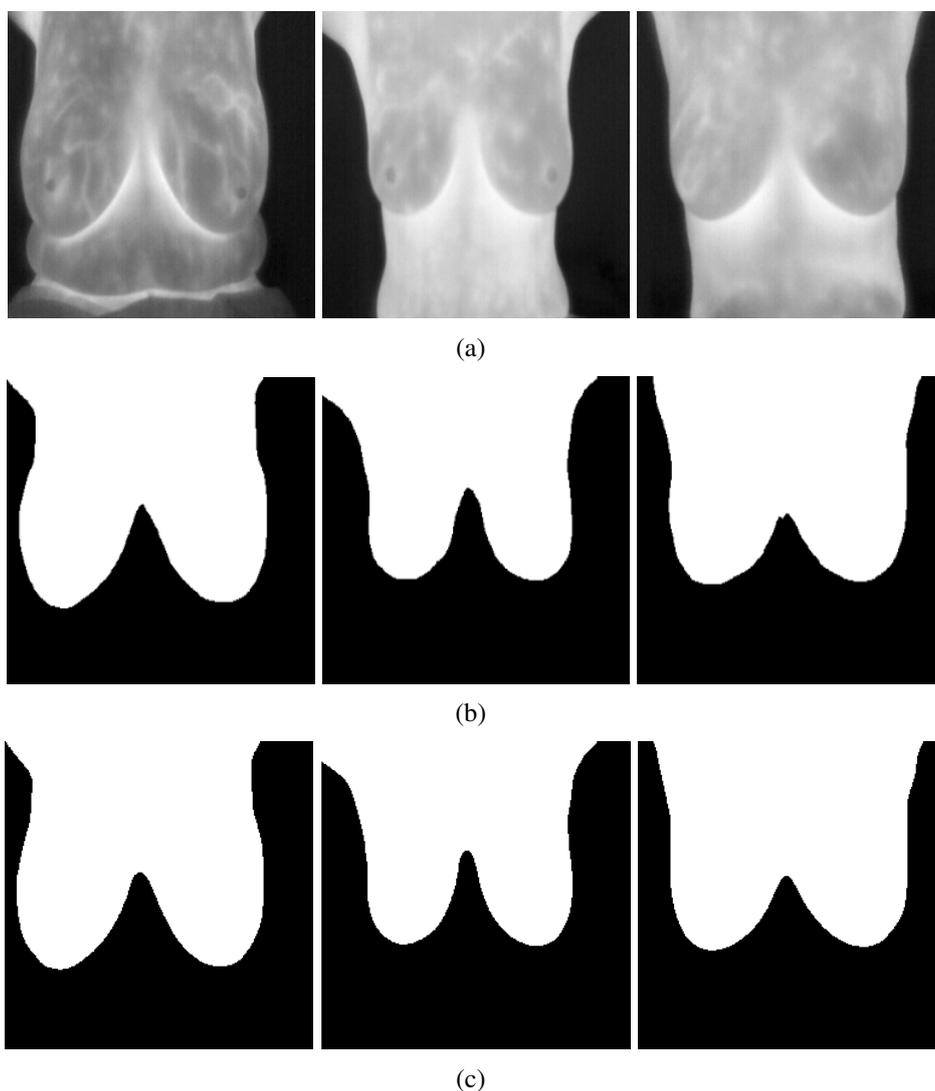
A Tabela 1 contém um comparativo entre os resultados obtidos neste trabalho e os demais trabalhos da literatura, citados na Seção II. Embora tenha sido desenvolvida para aplicações biomédicas, a U-Net demonstra uma performance superior comparado com outros métodos. O método proposto atinge o estado-da-arte nas métricas avaliadas mostrando não só a eficiência das Redes Neurais Convolucionais mas como uma tendência em aplicar métodos de aprendizado de máquina na solução de tarefas complexas do processamento e da análise de imagens.

Tabela 1. Comparação entre alguns métodos propostos na literatura.

Autor	Metodologia	Acurácia	IOU	Precisão	Revocação
[Motta 2010]	Limiarização	96%	-	-	88%
[Marques 2012]	Limiarização	97%	-	-	97%
[Baffa et al. 2016]	Limiarização	96%	-	-	98%
[Marques et al. 2016]	Limiarização	96%	-	-	97%
[Melo et al. 2017]	VGG-CNN	95%	-	-	97%
Método Proposto	U-Net CNN	98,24%	94,38%	98,86%	98,46%

Fonte: autor.

Figura 5. Resultados obtidos na segmentação pelo método proposto



Fonte: autor.

Em (a) as imagens originais, em (b) as respectivas segmentações manuais realizadas por um especialista e em (c) as segmentações automáticas realizadas pelo algoritmo proposto.

6. Conclusão

O problema de segmentação de imagens infravermelhas da mama é comumente abordado na literatura como um problema de processamento de imagens. Diferente dos métodos tradicionalmente utilizados, este trabalho visa aplicar técnicas de aprendizado de máquina para que, a partir da detecção de regiões de interesse padrões em termografias mamárias, possa criar uma máscara de segmentação. Os resultados obtidos com a proposta atingem o estado da arte e, de forma satisfatória, contribui para o desenvolvimento de sistemas CADx eficientes. Espera-se que para trabalhos futuros, novas camadas com enfoque em realizar a classificação da imagem seja adicionado ao método para que, de forma única, o método possa segmentar, extrair padrões das mamas e classificar se um determinado exame é proveniente de um paciente doente ou saudável.

Agradecimentos

A.C. é apoiada parcialmente pelo INCT (projeto MACC), pelo CNPq (projetos 402988 / 2016-7 e 305416 / 2018-9) e pela FAPERJ (projetos SIAD-2, e-Health Rio e Digit3D). M.B. é apoiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) (Projeto 88887.498626/2020-00). A.M.C. agradece ao FNDE pelo apoio na pesquisa junto ao Programa de Educação Tutorial (PET - Conexão de Saberes Ciência da Computação).

Referências

- Amalu, W., Hobbins, W., Head, J., and Elliot, R. (2006). Infrared imaging of the breast—an overview. *The Biomedical Engineering Handbook, 3rd ed., Medical Devices and Systems*. CRC Press, Baton Rouge.
- Baffa, M., Cheloni, D., and Lattari, L. (2016). Segmentação automática de imagens térmicas das mamas utilizando limiarização com refinamento adaptativo. In *Anais do XVI Workshop de Informática Médica*, pages 39–48. SBC.
- Baffa, M. F. O. and Lattari, L. G. (2018). Convolutional neural networks for static and dynamic breast infrared imaging classification. In *2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, pages 174–181. IEEE.
- Conci, A., Azevedo, E., and Leta, F. (2008). *Computação Gráfica: Teoria e Prática*, volume 2. Elsevier Editora.
- Gore, J. P. and Xu, L. X. (2003). Thermal imaging for biological and medical diagnostics. *Biomedical Photonics Handbook*, 17:1–12.
- IFF/Fiocruz. (2021). Câncer de mama: a importância do diagnóstico precoce. Disponível em: <<http://www.iff.fiocruz.br/index.php/8-noticias/274-cancerdemama>>. Acesso em: 05 abr. 2021.
- Instituto Nacional do Cancer. (2021). Câncer de mama. Disponível em: <<https://www.inca.gov.br/tipos-de-cancer/cancer-de-mama>>. Acesso em: 05 abr. 2021.
- Ismael, A. M. and Şengür, A. (2021). Deep learning approaches for covid-19 detection based on chest x-ray images. *Expert Systems with Applications*, 164:114054.
- Marques, R. S. (2012). Segmentação automática das mamas em imagens térmicas. Master's thesis, Instituto de Computação, Universidade Federal Fluminense, Niterói, RJ, Brasil.
- Marques, R. S., Conci, A., Perez, M. G., Andaluz, V. H., and Mejia, T. M. (2016). An approach for automatic segmentation of thermal imaging in computer aided diagnosis. *IEEE Latin America Transactions*, 14(4):1856–1865.
- Melo, R. H. C., Conci, A., and Vasconcelos, C. N. (2017). On the use of fully convolutional networks on evaluation of infrared breast image segmentations. In *Anais do XVII Workshop de Informática Médica*. SBC.
- Motta, L. S. (2010). Obtenção automática da região de interesse em termogramas frontais da mama para o auxílio à detecção precoce de doenças. Master's thesis, Instituto de Computação, Universidade Federal Fluminense, Niterói, RJ, Brasil.

- Rehman, A., Khan, M. A., Saba, T., Mehmood, Z., Tariq, U., and Ayesha, N. (2021). Microscopic brain tumor detection and classification using 3d cnn and feature selection architecture. *Microscopy Research and Technique*, 84(1):133–149.
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, pages 234–241. Springer.
- Silva, L., Saade, D., Sequeiros, G., Silva, A., Paiva, A., Bravo, R., and Conci, A. (2014). A new database for breast research with infrared image. *Journal of Medical Imaging and Health Informatics*, 4(1):92–100.
- U.S. National Cancer Institute. (2021). Breast cancer screening (pdq) - patient version. Disponível em: <<https://www.cancer.gov/types/breast/patient/breast-screening-pdq>>. Acesso em: 05 abr. 2021.
- Zuluaga-Gomez, J., Zerhouni, N., Al Masry, Z., Devalland, C., and Varnier, C. (2019). A survey of breast cancer screening techniques: thermography and electrical impedance tomography. *Journal of medical engineering & technology*, 43(5):305–322.