

Segmentação Multi-classes em termografias mamárias utilizando Redes Profundas

Gabriela Pinheiro Henriger
Instituto Politécnico - IPRJ

Universidade do Estado do Rio de Janeiro - UERJ
Nova Friburgo, RJ - 28625-570
Email: gabriela.henriger@grad.iprj.uerj.br

Sílvia Cristina Dias Pinto
Instituto Politécnico - IPRJ

Universidade do Estado do Rio de Janeiro - UERJ
Nova Friburgo, RJ - 28625-570
Email: silvia.dias@iprj.uerj.br

Abstract—Despite the many advances in medicine and science to combat breast cancer, recent studies regarding the incidence of the disease in Brazil and in the world show that this disease is one of the main causes of death among women. In order to collaborate with the early diagnosis of breast anomalies, increasing the chances of cure, breast thermography image has been used with the purpose of collaborating where mammography is unfavorable. Therefore, this work proposes to use the static protocol of thermography since it offers 5 points of view of the breast region, thus expanding the possibility of finding carcinomas. And, to find the region of interest in these images, we used the U-Net network architecture to perform a multi-class segmentation with the aim of providing a future step of more efficient thermographic pattern recognition between healthy and abnormal breasts. Preliminary results achieved an accuracy of 80,71% and a value of 0,82% for the IoU metric.

Resumo—Apesar dos muitos avanços da medicina e da ciência no combate ao câncer de mama, estudos recentes sobre a incidência da doença no Brasil e no mundo mostram que essa doença é uma das principais causas de morte entre as mulheres. A fim de colaborar com o diagnóstico precoce das anomalias mamárias, aumentando as chances de cura, a imagem da termografia mamária tem sido utilizada com o intuito de colaborar onde a mamografia é desfavorável. Assim, este trabalho propõe a utilização do protocolo estático de termografia, pois oferece 5 pontos de vista da região mamária, ampliando assim a possibilidade de encontrar carcinomas. E, para encontrar a região de interesse nessas imagens, utilizamos a arquitetura de rede U-Net para realizar uma segmentação multi-classes com o objetivo de fornecer uma etapa futura de reconhecimento de padrões termográficos mais eficientes entre mamas saudáveis e anormais. Os resultados preliminares alcançaram uma precisão de 80,71% e um valor de 0,82% para a métrica IoU.

I. INTRODUÇÃO

De acordo com o último relatório do INCA (Instituto Nacional de Câncer) [1], que trata das estimativas de incidência de Câncer no Brasil para 2020-2022, e que leva em consideração 19 localizações específicas de neoplasia maligna, o câncer de mama aparece em segundo lugar, com 2,1 milhões, no ranking de incidências mundiais, e o mais frequente quando considera-se apenas as mulheres (24,2% dos casos). Estimam-se que haverão, no Brasil, 66.280 novos casos (29,7% do total) de câncer de mama, para cada ano do triênio 2020-2022, o que corresponde à um risco previsto de 61,6 novos casos a cada 100 mil brasileiras. O mesmo relatório contabilizou em 2017, 16.724 óbitos por câncer de mama, o equivalente ao risco de


quase 16,2 mortes por 100 mil mulheres. Estes números estão de acordo com as ocorrências mundiais, que chama a atenção para uma das principais causas de morte entre as mulheres. Apesar dos muitos avanços na medicina e na ciência para o combate desta doença, de uma forma geral, estes números demonstram porque ainda é necessário fortalecer os estudos nesta área.

Em geral, as anormalidades mamárias costumam ser detectadas pelo autoexame através do toque (de paciente e/ou do médico) e/ou nos exames de imagem como mamografia, ultrassom, entre outros. O diagnóstico precoce da doença é fundamental devido à uma maior chance de cura, sujeitando a paciente à tratamentos menos invasivos, que requerem investimentos menores e mais eficientes no âmbito da gestão pública [2].


Normalmente, a mamografia é o exame considerado mais eficiente para rastrear e detectar de forma precoce o câncer de mama devido à sua precisão relativamente alta, baixo custo e alta sensibilidade [1]. No entanto, existem algumas desvantagens consideradas, isto é, para pacientes com tecidos mamários densos, geralmente entre 40 e 50 anos, deve-se conciliar-se o exame de ultrassom para resultados mais precisos. Outra inconveniência é em relação aos possíveis efeitos colaterais relacionados à radiação ionizada, os quais a paciente é exposta [3], além de apresentar dificuldade em detectar lesões muito pequenas (menores que 2 mm) ou presentes em seios cirurgicamente alterados [4].

Diante disso, apesar da termografia ainda não ser usada como um método de triagem para o câncer de mama devido ao seu notável índice de falsos positivos na abordagem para a categorização entre mamas normais e a [3], estudos recentes [5], [6], têm demonstrado que esta técnica é promissora onde a mamografia é desfavorável, isto é, o uso da termografia se torna uma boa aliada no diagnóstico por imagem, uma vez que não é invasiva, possui baixo custo, não discrimina faixa etária, é relativamente rápida de ser obtida e ainda pode ser utilizada por pacientes do sexo masculino [5].

Em resumo, o princípio da termografia se dá na conversão do infravermelho emitido por nossos corpos em sinais elétricos, os quais são interpretados como um termograma, promovendo uma acentuação das anormalidades em relação ao tecido normal, uma vez que as anormalidades apresentam



(a) Mama com presença de carcinoma.



(b) Mama saudável.

Figura 1. Exemplo de imagens obtidas através do exame de termografia [7] com e sem presença de carcinoma.

uma maior temperatura devido às alterações metabólicas e uma maior concentração de vasos sanguíneos que alimentam o tumor [8]. Normalmente, o desvio médio da maior temperatura de um tumor maligno em relação ao benigno é de $0,51^{\circ}\text{C}$, e em relação à uma mama saudável é de $0,85^{\circ}\text{C}$ [3]. Segundo McPherson [9], estas variações são produzidas antes mesmo de alterações clínicas e mamográficas. Desta forma, este exame pode ser utilizado para detecção precoce do câncer de mama, podendo detectar possíveis anomalias até 10 anos antes da mamografia. A Figura 1 apresenta dois exemplos de imagens obtidas através de um exame de termografia com presença e sem carcinoma [7].

Em relação à abordagem sobre a região de interesse (ROI) da imagem termográfica, alguns trabalhos [10], [11] utilizam a imagem original, mesmo havendo regiões consideradas ruidosas (desnecessárias para a tomada de decisão) como pescoço, partes da cabeça e do braço. Ao passo que, alguns concordam que técnicas de segmentação para obter a ROI são mais convenientes para obter uma classificação mais eficiente. Neste caso, [12] utilizou o software *ImageJ* enquanto que [13], [14] usaram um aplicativo público para *Tablet* [15], para obterem a máscara que representa a ROI. Outras opções consideraram a técnica de segmentação de imagens por limiar global (Método de Otsu) [16], e a fim de obter estas regiões de forma mais rápida e automática, o trabalho de [6] utilizou a arquitetura de rede profunda U-Net [17]. Ambas abordagens consideraram apenas a região das mamas das termografias com perfil frontal (estática ou dinâmica) [7], [13].

Quanto às metodologias para categorização entre mamas, ambos [10] e [16] utilizaram o método de Máquina de Vetores de Suporte (SVM), além do uso de Redes Neurais Artificiais (RNA) no segundo trabalho. Ambos consideraram como entrada as características extraídas da ROI, para classificar entre classes normais, com alterações benignas ou malignas, obtendo 84,7% e 80,95% de acurácia, respectivamente. Enquanto que [11] usou as imagens originais como conjunto de entrada para Redes Neurais Convolucionais (CNNs) levando em consideração técnicas de transferência de aprendizado, que consistem em usar CNNs pré-treinadas como extrator de características fixo. As arquiteturas avaliadas no trabalho de classificação foram AlexNet, GoogleNet, ResNet-18, vgg-16 e vgg-19, obtendo 77,5% de acurácia para as duas últimas, ao classificar as 5 poses (frontal, laterais e meio-

laterais) da termografia estática entre saudáveis e portadoras de câncer de mama. Ao passo que [6] usou as quatro primeiras arquiteturas usada por [11] para demonstrar que o seu modelo de CNN proposto apresentou o melhor resultado entre elas, isto é, 99,33% de acurácia. Enquanto que [12] e [14] usaram os classificadores SVM e K-star tendo como entrada um conjunto características extraídas a partir de séries temporais obtidas a partir da conversão das imagens termográficas para matrizes de temperatura, obtendo 95,71% e 95,8% de acurácia, respectivamente, entre mamas saudáveis e anormais.

Assim, este trabalho usufruirá da arquitetura de rede U-net [17], conforme [6], para obter uma ROI mais representativa considerando a região das mamas e axilas, já que, a região dos gânglios linfáticos, ou linfonodos, seria a primeira área a sofrer de metástase da neoplasia mamária [3], [4]. Logo, alterações nesta região são indicativos importantes para um diagnóstico preciso. Outra decisão tomada a partir das abordagens analisadas, foi em relação ao tipo de termografia, decidimos trabalhar com as estáticas, uma vez que estas oferecem um domínio de observação maior quando comparamos com a imagem frontal, ou seja, nossa proposta é usar a arquitetura U-Net para realizar uma segmentação multi-classe, considerando os cinco diferentes pontos-de-vistas da região mamária (Figura 2). Assim, espera-se com esta abordagem, aumentar a abrangência e generalidade de um modelo de classificação uma vez que este terá informações de outros ângulos da ROI, possibilitando uma etapa de reconhecimento padrões termográficos mais eficiente entre mamas saudáveis e anormais.

Dando sequência, apresentamos na seção II a base de imagens utilizado e os métodos de pré-processamento e segmentação abordados neste trabalho, seguindo dos resultados preliminares (seção III) e consequentemente das prévias conclusões e dos trabalhos futuros conforme a seção IV.

II. MATERIAL E MÉTODOS

A. Base de Dados

As termografias aqui utilizadas estão disponíveis de forma *online* desde 2017 na plataforma Visual Lab DMR [7], [13], a qual conta com exames de imagens da mama (termografia e algumas poucas mamografias) de pacientes voluntárias com diagnóstico: doente, saudável ou desconhecido; do Hospital Universitário Antônio Pedro, da Universidade Federal Fluminense, localizado na cidade de Niterói/RJ. A base disponibiliza




Figura 2. Exemplos dos cinco diferentes pontos-de-vistas via termografia estática da região mamária.

um histórico das pacientes com informações importantes para rastreamento e detecção de anomalias além das suas termografias mamárias. Para cada uma das cerca de 450 pacientes, há então um conjunto de termografias considerando os dois tipos de protocolos: estático e dinâmico. O primeiro, o envolve a captura de uma única imagem, capturada de 10 à 15 minutos após a estabilização de temperatura durante o descanso para 5 pontos-de-vistas diferentes, isto é, uma frontal, duas laterais e duas meio-laterais, utilizadas nos trabalhos de [16] e [11]. Já o segundo, implica em uma série de termogramas capturados a cada 15 segundos durante 5 minutos, as quais consideram apenas a vista frontal da paciente. São cerca de 20 capturas para cada paciente. Este protocolo foi usado nos trabalhos de [10], [12], [14] e [6]. De acordo com um levantamento recente [5], esta base é uma das mais usadas no âmbito de termografia mamária.

Neste trabalho consideraremos uma amostragem balanceada de 100 pacientes doentes e 100 saudáveis, e suas 5 termografias de protocolo estático, obtendo no total 479 imagens para ambas as classes (958 no total), já que para alguns pacientes não constam todas as posições disponíveis. Quando comparado com o trabalho de [11], contabilizamos um aumento de um pouco mais de 100% do número de amostras por ele considerada, justificativa essa que considera que o aumento de amostras na base de dados é uma característica crítica para a avaliação da performance do modelo.

B. Pré-processamento dos dados

As termografias originais são coloridas (RGB) e possuem a dimensão 640×480 pixels, mas devido aos métodos de segmentação e classificação a serem adotados, realizamos uma alteração da dimensão para 256×256 a fim de obtermos um custo computacional menor para o modelo proposto.

C. Segmentação da Região de Interesse

A U-Net é uma CNN cuja arquitetura se direciona à segmentação de imagens biomédicas. E considerando os bons resultados obtidos por [6], a usaremos para segmentar a área mama com axila das imagens termográficas. Em síntese, sua arquitetura tem formato de U, conforme detalha o artigo de Ronneberger et al [17]. As concatenações realizadas pela rede permitem que características específicas extraídas pelas convoluções do *contracting path* se unam com características do *expansive path*, promovendo um contexto mais geral da imagem, em diferentes escalas.

Apesar de estudos demonstrarem que a rede U-net apresenta resultados satisfatórios até mesmo para base de dados limitadas [6], de acordo com [17] a técnica de *Data Augmentation* proporciona a criação de outras imagens a partir de rotações, translações e escalonamento das imagens originais, promovendo a possibilidade de se obter um melhor desempenho e precisão na tarefa de segmentação.

Além disso, como ponto de partida para o treino da U-net, a técnica de Transferência de Aprendizado (TL) [18] foi utilizada com o objetivo de obter um progresso de aprendizado otimizado e de melhor desempenho para o modelo específico em que estamos trabalhando. Este procedimento reaproveita modelos pré-treinados em enormes bases de dados, pelas quais aprendem recursos gerais como arestas e formas, neste caso usou-se o reaproveitamento da ResNet34.

A fim de validar os resultados da segmentação obtida, além da precisão, a métrica IoU (*Intersection over Union*) [19] se demonstra mais intuitiva para Segmentação Semântica, estimando o quão bem as máscaras preditas concordam com o *ground truth*. Assim, seja A_P a área da máscara predita e A_O a área da máscara original (*ground truth*), a IoU é obtida pela equação:

$$IoU = \frac{|A_P \cap A_O|}{|A_P \cup A_O|}$$

III. RESULTADOS

Primeiro, com o propósito de ajustar os parâmetros para a U-Net, foi considerado um subconjunto de 70 imagens frontais dinâmicas para que pudéssemos confrontar com o resultado obtido por [6] ainda que consideramos a região das axilas. O segundo subconjunto avaliado considerou 71 termografias estáticas, isto é, imagens de 5 poses estáticas de 14 pacientes, conforme a meta deste trabalho que é realização de uma segmentação multi-classe. Devido ao requisito de entrada da U-Net, foram gerados máscaras da ROI para ambos os subconjuntos usando as ferramentas de processamento de imagens *Label Studio* e *ImageJ*.

Em relação à tarefa de ajuste dos parâmetros do método de U-Net para a segmentação, foi considerado a proporção 75:25 imagens para treino e teste respectivamente. Para o subconjunto de imagens dinâmicas, consideramos o método ADAM (*Adaptive Moment Estimation*), como algoritmo otimizador e um raio de aprendizado igual à 1.0^{-3} . O número de passos por épocas foi 23 e o número de épocas iguais à 80. A mesma abordagem foi utilizada para o conjunto




Figura 3. Etapas da abordagem de Segmentação usando U-Net.

Tabela I
RESULTADOS OBTIDOS PARA A ABORDAGEM DE SEGMENTAÇÃO.

| Subconjunto | Número de amostras | Precisão | IoU |
|------------------------|--------------------|----------|------|
| termografias dinâmicas | 70 | 86,04% | 0,74 |
| termografias estáticas | 71 | 80,71% | 0,82 |

estático, com exceção do número de épocas, reduzido para 35 para evitar um *overfitting*. Resultados prévios obtidos sem o uso do método de *Data Augmentation* justificam o seu uso durante o treinamento da rede, ou seja, a técnica melhorou a precisão alcançada. O mesmo comportamento se observou em relação aplicação da aplicação da técnica de Transferência de Aprendizado. A Figura 3 apresenta um exemplo das etapas de segmentação para o subconjunto das termografias dinâmicas e a Tabela I revela os resultados obtidos para a segmentação dos subconjuntos de termografias considerados.

IV. DISCUSSÃO E CONCLUSÃO

Este trabalho propõe uma segmentação multi-classe de imagens de termografias estáticas usando o algoritmo de aprendizado profundo chamado U-Net. Pelos resultados preliminares obtidos, em relação ao subconjunto de imagens frontais dinâmicas, podemos concluir que os parâmetros escolhidos para a U-Net foram satisfatórios, mesmo não tendo como confrontar com os resultados obtidos na etapa de segmentação do trabalho Mohamed et al [6], uma vez que o mesmo não apresentou os resultados pertinentes da segmentação. Já para o caso do subconjunto das 5 poses das imagens estáticas, ao compararmos com o resultado do primeiro subconjunto, o qual considerou apenas uma classe de imagens, concluímos que a abordagem adotada se justifica já que, considerar um conjunto de diferentes posições termográficas para detectar anomalias só vem a contribuir no diagnóstico por imagem. Podemos observar que a imagem segmentada na Figura 3[d] apresenta ainda uma parte lateral do fundo da imagem, e portanto ainda deveremos trabalhar para obtermos melhores resultados em relação a isso. Além disso, na próxima etapa deste trabalho, pretende-se realizar a partir destes resultados, as etapas de classificação das termografias usando métodos de classificação para comparara com o trabalho de Chaves [11], que utilizou 5 diferentes CNNs a partir da termografia sem considerar ROI.

REFERÊNCIAS

- [1] INCA, *Estimativa 2020 : incidência de câncer no Brasil*. Rio de Janeiro: Ministério da Saúde, 2019.
- [2] FEMAMA, “Câncer de mama: entenda as diferenças entre prevenção e detecção precoce,” 2019.
- [3] T. B. Borchardt, A. Conci, R. C. Lima, R. Resmini, and A. Sanchez, “Breast thermography from an image processing viewpoint: A survey,” *Signal Processing*, vol. 93, no. 10, pp. 2785–2803, 2013, signal and Image Processing Techniques for Detection of Breast Diseases.
- [4] J. Singh and A. S. Arora, “Automated approaches for rois extraction in medical thermography: A review and future directions,” *Multimedia Tools Appl.*, vol. 79, no. 21–22, p. 15273–15296, 2020.
- [5] R. Roslidar, A. Rahman, R. Muharar, M. R. Syahputra, F. Arnia, M. Syukri, B. Pradhan, and K. Munadi, “A review on recent progress in thermal imaging and deep learning approaches for breast cancer detection,” *IEEE Access*, vol. 8, pp. 116176–116194, 2020.
- [6] E. A. Mohamed, E. A. Rashed, T. Gaber, and O. Karam, “Deep learning model for fully automated breast cancer detection system from thermograms,” *PLOS ONE*, vol. 17, no. 1, pp. 1–20, 01 2022.
- [7] L. F. da Silva, D. C. M. Saade, G. O. Sequeiros, A. C. Silva, A. C. de Paiva, R. de Souza Bravo, and A. Conci, “A new database for breast research with infrared image,” *Journal of Medical Imaging and Health Informatics*, vol. 4, pp. 92–100, 2014.
- [8] E. Gerasimova, O. Plekhov, Y. Bayandin, O. Naimark, and G. Freynd, “Identification of breast cancer using analysis of thermal signals by nonlinear dynamics methods,” 01 2012.
- [9] K. McPherson, C. M. Steel, and J. M. Dixon, “Breast cancer—epidemiology, risk factors, and genetics,” *BMJ*, vol. 321, no. 7261, pp. 624–628, 2000.
- [10] C. N. S. Belfort, “Análise e classificação de termografias dinâmicas da mama utilizando a variação de temperatura e máquina de vetores de suporte,” 2016.
- [11] E. d. L. Chaves, “Detecção de câncer de mama por meio de imagens infravermelhas utilizando redes neurais convolucionais,” 2019.
- [12] L. F. d. Silva, “Uma análise híbrida para detecção de anomalias da mama usando séries temporais de temperatura,” Ph.D. dissertation, Universidade Federal Fluminense, 2015.
- [13] G. O. Sequeiros, “Desenvolvimento de um banco de dados de imagens mastológicas acessíveis via web com recuperação de imagens baseada em conteúdo,” Master’s thesis, Universidade Federal Fluminense, 2013.
- [14] F. J. P. Andrade, A. C. Paiva, and A. C. Silva, “Análise de imagens de termografia dinâmica para classificação de alterações na mama usando séries temporais,” in *SIBGRAPI*. Niterói, RJ, Brazil: SBC, 10 2017.
- [15] R. d. S. Marques, “Segmentação automática das mamas em imagens térmicas,” Master’s thesis, Universidade Federal Fluminense, 2012.
- [16] C. B. Gonçalves, “Detecção de câncer de mama utilizando imagens termográficas,” 2017.
- [17] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Springer International Publishing, 2015, pp. 234–241.
- [18] R. Ribani and M. Marengoni, “A survey of transfer learning for convolutional neural networks,” 10 2019, pp. 47–57.
- [19] H. Rezatofghi, N. Tsoi, J. Gwak, A. Sadeghian, I. Reid, and S. Savarese, “Generalized intersection over union,” June 2019.