

Estudo Comparativo para Segmentação de Melanoma em Imagens de Lesões de Pele

Rafael Luz Araújo¹, Romuere R. V. e Silva^{1,2}, Jonnison Lima Ferreira²,
Nonato R. de S. Carvalho¹

¹ Programa de Pós-Graduação em Engenharia Elétrica (UFPI) Picos/Teresina, Brasil.

²Sistemas de Informação (UFPI) Picos, Brasil.

{rafaluzaraujo, romuere, nrdesales}@ufpi.edu.br, jonnison@nca.ufma.br

Abstract. *Among skin cancers, melanoma is the leading cause of fatalities and has been increasing worldwide, and the discovery of the pathology in the early stages is essential to increase the chances of cure. Computational methods are being developed to facilitate its detection through medical imaging. To interpret information in these images efficiently, it is necessary to isolate the injured region. In this research a comparison was made between segmentation techniques. At first, a method based on the Otsu algorithm and one based on deep learning U-net were developed. The tests performed on the PH2 image database had promising results, especially U-net.*

Resumo. *Dentre os cânceres de pele, o melanoma é o principal causador de fatalidades e vem aumentando sua incidência pelo mundo, sendo fundamental a descoberta da patologia nas fases iniciais para aumentar as chances de cura. Métodos computacionais estão sendo desenvolvidos para facilitar a sua detecção através de imagens médicas. Para interpretar informações nessas imagens de forma eficiente é necessário isolar a região com lesão. Nesta pesquisa realizou-se uma comparação entre técnicas de segmentação. A princípio, foi desenvolvido um método baseado no algoritmo de Otsu e outro baseado em aprendizagem profunda U-net. Os testes realizados na base de imagens PH2 tiveram resultados promissores, com destaque para a U-net.*

1. Introdução

O número de pessoas com câncer vem aumentando em todo o mundo, a Agência Internacional de Pesquisa Sobre o Câncer (IARC) divulgou que em 2018 a estimativa da carga global de câncer tenha aumentado para 18,1 milhões de novos casos e 9,6 milhões de mortes [IARC 2018]. Esta pesquisa aborda o câncer conhecido como melanoma cutâneo que se origina nos melanócitos (células produtoras de melanina).

Dentre os cânceres de pele, o melanoma é o principal causador de fatalidades e vem aumentando sua incidência pelo mundo. Conforme a Organização Mundial da Saúde (OMS), ocorrem no mundo cerca de 132.000 novos casos de melanoma a cada ano [WHO 2019]. Para [Inca 2019] a partir da pele normal ou de uma lesão pigmentada pode surgir o melanoma. Na pele normal, a manifestação da doença se dá após o aparecimento de uma pinta escura de bordas irregulares acompanhada de coceira e descamação.

Se o melanoma for detectado nos estágios iniciais há mais chances de cura e melhoria na sobrevivência dos pacientes. A necessidade de descobrir a doença nos estágios

iniciais somado ao aumento do número de casos de câncer impulsionaram as pesquisas com finalidade de produzir formas de diagnosticar as patologias de forma precoce. Assim, ocorreu um alinhamento entre medicina e computação, através da aplicação de técnicas de reconhecimento de padrões e processamento de imagens em exames médicos visando a obtenção de laudos automáticos e precisos, com menor custo e maior agilidade, possibilitando ao médico um pré-diagnóstico.

Segundo [Pedrini and Schwartz 2008], processamento de imagens refere-se à transformação de uma imagem sucessivamente para que se possa extrair mais facilmente as informações contidas nela. É possível interpretar informações visuais em exames através da análise de cor, forma e textura obtendo uma descrição de determinada região da imagem através da extração de características estáticas que ela possui.

A segmentação da lesão cutânea nas imagens dermatoscópicas tem sido alvo de muitas pesquisas. Para uma melhor classificação da lesão é necessário que ela seja analisada de forma isolada, sem a interferência de ruídos ao fundo. Porém, isolar a região de interesse é uma tarefa difícil, pois as imagens possuem além da lesão diversos elementos como sombras, pelos e outros tipos de ruídos [Tang et al. 2019].

Assim, este artigo se propõe a realizar um estudo comparativo para segmentação de melanoma em imagens de lesões de pele. Para tanto, será utilizada a técnica tradicional Otsu em comparação com a rede neural convolucional U-net.

2. Trabalhos Relacionados

Esta seção é voltada para abordagens de alguns trabalhos da literatura desenvolvidos com métodos de segmentação para que se possa analisar cada metodologia utilizada.

[Fan et al. 2017] propôs um algoritmo de segmentação que inclui dois estágios. No estágio de aprimoramento as informações referentes a pele saudável são extraídas e os mapas de saliências de cores e brilho são construídos. Ao fundir os dois mapas de saliência o objeto da lesão é aprimorado. No estágio de segmentação, o limiar de Otsu é ajustado por uma função de otimização, por fim são removidos pontos e orifícios e obtém-se a segmentação final. Na base PH2 tiveram índice Dice de 0,8935.

No trabalho de [Peng et al. 2019] é proposta uma arquitetura de segmentação baseada em redes adversárias. A arquitetura consistem em uma rede U-net de segmentação e uma rede de discriminação vinculadas por determinadas camadas convolucionais. As duas rede são treinadas alternadamente obtendo uma alta precisão na segmentação. Na base PH2 obteve 0,9000 de coeficiente Dice.

Em [Bi et al. 2016] foi proposto um novo método de segmentação automatizada de lesões cutâneas por meio de aprendizado supervisionado por imagem (ISL) e autômatos celulares baseados em superpixel em escala múltipla (MSCA) resultando em índice Dice de 0,8157. No trabalho de [Ahn et al. 2017] foi sugerido que a detecção de saliência usando os erros de reconstrução derivados de um modelo de representação esparsa juntamente com uma nova detecção de fundo pode discriminar com mais precisão a lesão das regiões circundantes. Proporam também uma estrutura bayesiana que delinea melhor a forma e os limites da lesão. O método SLS proposto resultou em 0,7838 de média Dice.

Em relação aos trabalhos, observa-se a necessidade de melhorar os resultados

em [Bi et al. 2016] e [Ahn et al. 2017] pois ficaram mais distantes dos outros. Já em [Peng et al. 2019] como a rede adversária é constituída de duas redes que aprendem entre si, demanda maior poder computacional. A proposta da metodologia em questão é desenvolver uma rede U-net simplificada, que seja mais rápida e que obtenha resultados semelhantes com um custo computacional reduzido. Também será desenvolvida uma metodologia baseada em Otsu para servir de comparação com a rede U-net.

3. Materiais e Métodos

O método proposto neste trabalho tem por finalidade a segmentação de melanoma em imagens dermatológicas e seguirá etapas apresentadas na Figura 1, iniciando pela aquisição de imagens onde foi escolhida a base PH2, realização da segmentação com algoritmo de Otsu e rede U-net, por fim a validação com o coeficiente Dice.




Figura 1. Fluxograma de etapas da metodologia.

3.1. Aquisição de Imagens

A etapa de aquisição de imagens consiste em reunir as imagens com lesões cutâneas e mascaras de segmentação feitas por médicos para serem utilizadas na pesquisa. A base escolhida foi a PH2, que possui 200 imagens sendo 40 melanoma e 160 não melanoma [Mendonca et al. 2015]. Na Figura 2, em (a) temos um exemplo de lesão cutânea e em (b) a mascara de segmentação do médico.




Figura 2. Exemplo de lesão e mascara da base PH2

3.2. Segmentação

3.2.1. Otsu

A segmentação utilizando o algoritmo Otsu ocorreu seguindo as etapas da Figura 3. Inicialmente em (a) foram realizados testes entre os canais red, green e blue, além de níveis de cinza onde o canal green obteve os melhores resultados. Em (b) as imagens foram borradas utilizando o filtro de média para suavizar os pelos com o intuito de descartá-los durante a binarização. Já em (c), as imagens foram binarizadas com o limiar de Otsu e ao mesmo tempo, realizava-se a operação morfológica fechamento (dilatação seguida de uma erosão) com o elemento estruturante do tipo círculo de tamanho 5 para remover artefatos soltos sem afetar a região da lesão. Em (d) realizou-se a inversão da faixa de intensidade da imagem de entrada, para que o tipo máximo virasse o mínimo e vice-versa

para que em (e) fossem removidos os objetos conectados as bordas da imagem, com a operação de segmentação limpar bordas. Por fim, em (f) as regiões da imagem eram identificadas e uma mascara é criada com as coordenadas da região de maior área, eliminando regiões soltas que não fazem parte da lesão.




Figura 3. Metodologia de segmentação proposta com Otsu

3.2.2. U-net

O modelo de aprendizagem profunda baseado na U-Net criado nessa pesquisa difere da proposta por [Ronneberger et al. 2015] em sua quantidade de camadas e sua arquitetura pode ser vista na Figura 4. Do lado esquerdo tem-se o caminho de contração para capturar o contexto. De forma simétrica, tem-se do lado direito o caminho de expansão, que permite uma localização precisa. A entrada da rede é uma imagem RGB da lesão cutânea e a máscara de segmentação do médico. O modelo tem quatro camadas de subamostragem que possuem função de ativação média. É utilizada uma convolução transposta no caminho de expansão. As convoluções são seguidas por uma camada de normalização de batch e uma de Dropout de 20%. Ao final, a segmentação é gerada por uma convolução (1 x 1) com função de ativação sigmóide.




Figura 4. Arquitetura da rede U-net proposta.

3.3. Validação

Nesta pesquisa, é utilizado para validação, o índice Dice (DSC), que é amplamente utilizado como medida para desempenho da segmentação e indica a proporção de pixels compartilhadas entre duas amostras em relação ao total de pixels. Seu valor varia de 0% (nenhuma correspondência) até 100% (total correspondência) entre os volumes. O Dice é calculado pela Equação 1, onde VP significa verdadeiro positivo, que é quando

os pixels são classificados corretamente como melanoma. FP é falso positivo, quando os pixels são classificados erradamente como melanoma e FN falso negativo, quando o pixel é classificado erradamente como não melanoma [Ginsberg and Young 1992].

$$DSC = \frac{2 * VP}{2 * VP + FP + FN} \quad (1)$$

4. Experimentos e Análise dos resultados

Após segmentar todo o conjunto de imagens com as metodologias propostas, foi calculada a média DSC de todas as segmentações. A Tabela 1 apresenta os resultados das metodologias desenvolvidas e dos trabalhos relacionados. Obteve-se, como melhor resultado do algoritmo de Otsu proposto, a média DSC = 0,8090. Percebeu-se que os resultados da técnica tradicional são prejudicados por diversos fatores como baixo contraste, presença de pelos em cima da lesão, limites não bem definidos e existência de outros artefatos.

Para tentar contornar esses problemas foi utilizado um modelo de aprendizagem profunda baseado em U-Net. O modelo proposto necessita que todas as imagens de entrada estejam no mesmo tamanho, que deve ser múltiplo de 4. Porém, a base PH2 possui imagens de tamanhos variados, em sua maioria 765×574 . Por isso, realizou-se um redimensionamento para 32×32 e 128×128 pixels, que conseqüentemente também diminui o tempo de processamento. A rede foi executada 10 vezes modificando-se o número de épocas de 50 até 300 e a divisão do conjunto de dados. Identificou-se que 150 épocas eram suficientes para encontrar os melhores resultados e a melhor divisão do conjunto de dados foi 60% para treino, 20% para teste e 20% para validação. Para o conjunto de 32×32 obteve-se a média DSC = 0,8723. Porém, o melhor resultado foi com o conjunto 128×128 que atingiu DSC = 0,8924. Os resultados indicam que a U-net se adaptou melhor as adversidades da segmentação de melanoma que a técnica tradicional Otsu.

Observa-se que a aprendizagem profunda obtém resultados melhores que os métodos tradicionais porém com uma diferença sutil. A técnica proposta por [Peng et al. 2019] obteve resultado melhor que a proposta nesse trabalho. Porém, vale ressaltar, que por ela ser uma rede adversária é composta por duas redes que aprendem entre si, dentre elas uma U-net, o que a torna mais lenta que a U-net proposta.

Tabela 1. Comparação da metodologia com os trabalhos relacionados

Trabalho	Metodologia	Média Dice
[Peng et al. 2019]	Rede Adversária com U-net	0,9000
[Fan et al. 2017]	Otsu	0,8939
Metodologia proposta	U-net	0,8924
[Bi et al. 2016]	Outros	0,8157
Metodologia proposta	Otsu	0,8090
[Ahn et al. 2017]	Outros	0,7838

5. Conclusão e Trabalhos futuros

Este trabalho apresentou uma comparação entre metodologias para segmentação de melanoma. Para isso, foi desenvolvida uma técnica utilizando o algoritmo de Otsu tradicional e outra utilizando aprendizagem profunda baseada em U-net. Os testes foram realizados com a base de melanoma PH2 e foram obtidos resultados promissores, sendo 0,8090

de coeficiente Dice para a metodologia Otsu e 0,8924 para a U-net. Os resultados indicam que a rede U-net mostrou-se mais eficiente para segmentação do melanoma que a técnica convencional. Em comparação com outras pesquisas recentes, obteve resultado bem próximo, diferindo apenas em 0,0076% mas com a vantagem de ser mais rápida.

Para trabalhos futuros pretende-se modificar as técnicas afim de melhorar os resultados. Também pretende-se segmentar utilizando uma proposta de Rede Geradora Adversária. Além de realizar a classificação do melanoma utilizando técnicas convencionais de extração de características e as Redes Neurais Convolucionais.

Referências

- Ahn, E., Kim, J., Bi, L., Kumar, A., Li, C., Fulham, M., and Feng, D. D. (2017). Saliency-based lesion segmentation via background detection in dermoscopic images. *IEEE journal of biomedical and health informatics*, 21(6):1685–1693.
- Bi, L., Kim, J., Ahn, E., Feng, D., and Fulham, M. (2016). Automated skin lesion segmentation via image-wise supervised learning and multi-scale superpixel based cellular automata. In *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)*, pages 1059–1062. IEEE.
- Fan, H., Xie, F., Li, Y., Jiang, Z., and Liu, J. (2017). Automatic segmentation of dermoscopy images using saliency combined with otsu threshold. *Computers in biology and medicine*, 85:75–85.
- Ginsberg, J. R. and Young, T. P. (1992). Measuring association between individuals or groups in behavioural studies. *Animal Behaviour*, 44(1):377–379.
- IARC (2018). Latest global cancer data: Cancer burden rises to 18.1 million new cases and 9.6 million cancer deaths in 2018. *International Agency for Research on Cancer*.
- Inca (2019). Instituto Nacional do Câncer. <http://www1.inca.gov.br>. Online; acessado 02 de Setembro 2019.
- Mendonca, T., Celebi, M., Mendonca, T., and Marques, J. (2015). Ph2: A public database for the analysis of dermoscopic images. In *Dermoscopy image analysis*. CRC Press.
- Pedrini, H. and Schwartz, W. R. (2008). *Análise de imagens digitais: princípios, algoritmos e aplicações*. Thomson Learning.
- Peng, Y., Wang, N., Wang, Y., and Wang, M. (2019). Segmentation of dermoscopy image using adversarial networks. *Multimedia Tools and Applications*, 78(8):10965–10981.
- 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.
- Tang, P., Liang, Q., Yan, X., Xiang, S., Sun, W., Zhang, D., and Coppola, G. (2019). Efficient skin lesion segmentation using separable-unet with stochastic weight averaging. *Computer methods and programs in biomedicine*, 178:289–301.
- WHO (2019). World Health Organization. <http://www.who.int/uv/faq/skincancer/en/index1.html>. Online; Acesso em: 02 de Setembro 2019.