

Segmentação Baseada Em Superpixels Para Avaliar Os Impactos Da Supervisão Na Segmentação De Lesões Melanocíticas Em Imagens Macroscópicas

Mauricio S. Ferreira¹, Eliezer Soares Flores¹

¹Universidade Federal do Pampa - UNIPAMPA
Alegrete – RS – Brasil

{mauricioferreira.aluno, eliezerflores}@unipampa.edu.br

Abstract. *Melanoma is a skin cancer that can be extremely aggressive in its final stages and can, in some cases, develop metastasis. Therefore, proposals to improve the use of computational systems, in this context, have been widely investigated. In the present work, two variations, one supervised and the other unsupervised, of a method for the segmentation of macroscopic images of melanocytic lesions were investigated. Before the actual segmentation, the input image is pre-processed and then represented by superpixels. Subsequently, a clustering algorithm is fed with the extracted data and partitions it into two groups: lesion regions (foreground) and non-lesion regions (background).*

Resumo. *O melanoma é um câncer de pele que pode ser extremamente agressivo em seus estágios finais, podendo, em alguns casos, desenvolver metástase. Por isso, propostas para aperfeiçoar o uso de sistemas computacionais, neste contexto, vêm sendo amplamente investigadas. No presente trabalho, investigou-se duas variações, uma supervisionada e outra não supervisionada, de um método para a segmentação de imagens macroscópicas de lesões melanocíticas. Antes da segmentação propriamente dita, a imagem de entrada é préprocessada, em seguida, é representada por superpixels. Subsequentemente, um algoritmo de aglomeração é alimentado com os dados extraídos e, particiona em dois grupos: às regiões de lesão (foreground) e não lesão (background).*

1. Introdução

Sistemas que se baseiam em visão computacional e reconhecimento de padrões têm sido empregados para facilitar o diagnóstico de lesões melanocíticas através de imagens macroscópicas [Esteve et al. 2017].¹ Esses sistemas recebem uma imagem como entrada e, ao fim de seu processo, classificam a lesão de interesse contida na imagem (por exemplo, como “melanoma maligno” ou “nevo atípico benigno”). Tais sistemas podem ser divididos, tradicionalmente, em quatro etapas principais [Bernart et al. 2019]:

- pré-processamento: manipulação da imagem, de modo que facilite as próximas etapas do processo;
- segmentação: delimitação do objeto de interesse, com o intuito de separar o que é lesão do que não é lesão;

¹Esse tipo de imagem (por exemplo, uma fotografia tirada com um *smartphone* qualquer) é obtida sem o uso de iluminação controlada ou aparelhos especializados.

- caracterização: representação do objeto de interesse por um conjunto de características;
- classificação: distinção entre os diferentes tipos de lesões melanocíticas avaliadas a partir das características obtidas na etapa anterior.

Vários métodos supervisionados de segmentação têm sido propostos na literatura e, frequentemente, baseiam-se no treinamento de uma CNN (*Convolutional Neural Network* – rede neural convolucional) com arquitetura adaptada para a segmentação. Exemplos representativos desse tipo de abordagem incluem os trabalhos de [Nasr-Esfahani et al. 2016], [Al-Masni et al. 2018] e [Hasan et al. 2020]. Uma vez que reconhecem padrões com base em exemplos, esses métodos são capazes de produzir resultados satisfatórios, porém, além de demandarem uma quantidade considerável de imagens com pixels rotulados para o treinamento, são suscetíveis a causar problemas tais como aqueles relatados em [Bissoto et al. 2019].

Embora diversos métodos não supervisionados de segmentação podem ser encontrados na literatura (veja, por exemplo, [Flores and Scharcanski 2016] e/ou [Zortea et al. 2017]), os impactos da supervisão em termos de desempenho ainda têm sido pouco investigados. Por isso, o objetivo deste trabalho é avaliar os efeitos práticos de incorporar supervisão na etapa de segmentação. Efetivamente, até o momento, investigou-se duas variações, uma supervisionada e outra não supervisionada, de um método simples para a segmentação de imagens macroscópicas de lesões melanocíticas, baseado na representação da imagem em superpixels. O restante deste manuscrito está organizado da seguinte forma: a Seção 2 apresenta o método proposto e suas variantes; a Seção 3 contém os resultados e discussões preliminares; a Seção 4 apresenta as considerações finais e os trabalhos a serem realizados no futuro.

2. Método Investigado

O método investigado, tanto na sua versão supervisionada quanto na sua versão não supervisionada, começa com a aplicação do algoritmo SLIC (*Simple Linear Iterative Clustering*) [Achanta et al. 2012] para particionar o conjunto de pixels da imagem em subconjuntos de pixels similares (i.e., superpixels), reduzindo assim o número de elementos a serem considerados na segmentação. Note que diferentes configurações das versões do método investigado podem ser produzidas variando o hiperparâmetro que controla a quantidade de superpixels, resultando assim em superpixels tais como aqueles ilustrados na Figura 1.

Em seguida, para cada superpixel obtido, diversas características podem ser extraídas. De fato, configurações das versões do método investigado foram analisadas com:

- 3 atributos, de modo que cada superpixel é representado pelos valores das médias dos canais R, G e B;
- 6 atributos, de forma que cada superpixel é descrito não só pelos valores das médias, mas também pelos valores dos desvios-padrão dos canais R, G e B;
- 7 atributos, de maneira que cada superpixel é representado pelos valores das médias e dos desvios-padrão dos canais R, G e B, bem como pela distância do centro do superpixel até o centro da imagem.²

²O método investigado baseia-se na premissa que a lesão de interesse deve ser o foco principal de atenção durante a aquisição da imagem, de modo que tende a aparecer mais próxima do centro da imagem.

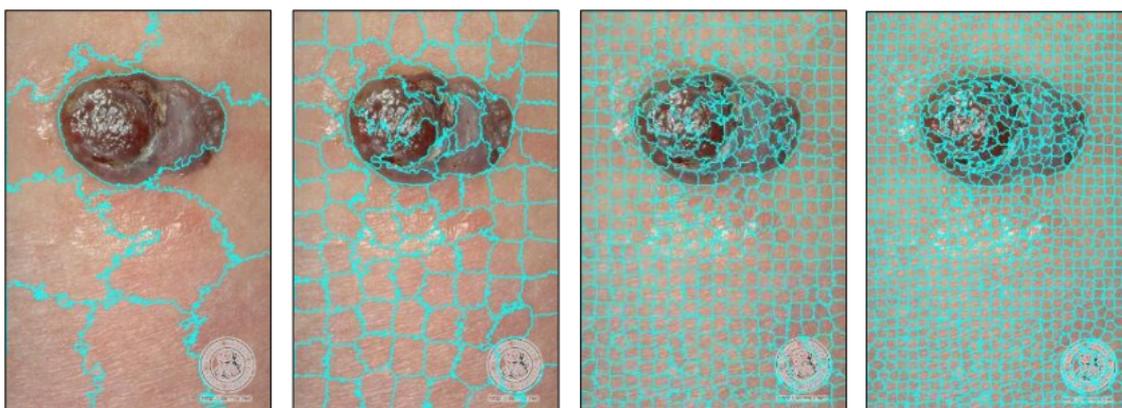


Figura 1. Ilustração dos resultados obtidos após aplicar o SLIC para particionar uma mesma imagem em diferentes quantidades de superpixels.

Por fim, a versão supervisionada do método investigado realiza a discriminação entre os “superpixels de lesão” e “superpixels de não lesão” (i.e., a segmentação) aplicando o algoritmo KNN (*K-Nearest Neighbors* – K vizinhos mais próximos) e difere-se da versão não supervisionada que consiste em aplicar um algoritmo de agrupamento (do inglês, *clustering*) para efetuar essa mesma discriminação. Observe que diferentes configurações da versão supervisionada podem ser geradas alterando o hiperparâmetro K que controla a quantidade de exemplos de treinamento a serem considerados para realizar a classificação. De maneira análoga, diversas configurações da versão não supervisionada podem ser produzidas variando a quantidade de agrupamentos e também o algoritmo de agrupamento (as opções *K-means*, *GMM – Gaussian Mixture Model* – e *Mean Shift* foram avaliadas).

Cabe ainda mencionar que, antes de efetivamente segmentar a imagem, foi empregado o método de pré-processamento proposto em [Cavalcanti et al. 2010],³ a fim de corrigir irregularidades de iluminação que podem induzir erros de segmentação. A fim de refinar e padronizar o resultado da segmentação, também foram empregadas duas etapas de pós processamento, a saber, um preenchimento de buracos e uma eventual inversão de valores para assegurar que a maioria dos superpixels seja identificada como “não lesão”.

3. Resultados Experimentais e Discussões

O método investigado foi avaliado utilizando a base de imagens disponibilizada publicamente em [University of Waterloo 2013]. Tal base contém 86 imagens, sendo 43 imagens macroscópicas de lesões melanocíticas e 43 imagens binárias geradas por médicos especializados em dermatologia (i.e., *ground truths*).⁴ As métricas utilizadas para a avaliação do desempenho de segmentação, por sua vez, foram o erro XOR e o coeficiente de *Sørensen–Dice* (conhecido também como índice de DICE).

Para avaliar o método investigado, primeiramente, foi realizado um particionamento das imagens em dois subconjuntos: um subconjunto de treinamento com 80% das imagens e um subconjunto de teste com 20% das imagens.

³Basicamente, esse método consiste em modificar o canal V do espaço de cores HSV com base em um modelo quadrático de iluminação regular ajustado a partir dos quatro cantos do canal em questão.

⁴O trabalho de [Glaister et al. 2014], por exemplo, faz uso desta mesma base de dados.

Para selecionar a configuração ótima para a versão supervisionada do método investigado, uma validação cruzada do tipo *5-fold* foi empregada sobre o subconjunto de treinamento. Desse modo, foram avaliadas todas as configurações com o hiperparâmetro do SLIC (i.e., o número de superpixels desejado) em {100, 200, 400, 800} e com o hiperparâmetro K do KNN em {3, 5, 7, 9}.

Após avaliar as dezesseis possibilidades de configurações, com base no índice Dice, foi selecionada a configuração com os hiperparâmetros 100 e 9, a qual foi treinada novamente, mas agora com todo o subconjunto de treinamento, e cujos resultados no subconjunto de teste estão apresentados na Tabela 1.

Tabela 1. Resultados obtidos com a variação supervisionada do método investigado.

Método	3 Atributos	6 Atributos	7 Atributos
Índice de DICE	0,802768166	0,842465753	0,854237288
Erro XOR	0,390410959	0,315068493	0,294520548

Conforme pode-se observar, existe uma certa estabilidade entre as configurações testadas, sendo, contudo, possível aferir uma tendência de melhora com um aumento no número atributos.

Os resultados obtidos nos testes com a versão não supervisionada do método investigado, por sua vez, estão apresentados na Tabela 2 (todos os testes realizados empregaram um particionamento da imagem com 100 superpixels).

Tabela 2. Resultado obtidos com a variação não supervisionada do método investigado.

3 Atributos			
Método	K-means	GMM	Mean Shift
Índice de DICE	0,851228910	0,821982953	0,840715623
Erro XOR	0,367519448	0,446924402	0,637494367
6 Atributos			
Método	K-means	GMM	Mean Shift
Índice de DICE	0,848864489	0,818101235	0,837280046
Erro XOR	0,375375965	0,451303120	0,653966141
7 Atributos			
Método	K-means	GMM	Mean Shift
Índice de DICE	0,712218534	0,797445223	0,767861575
Erro XOR	1,000000000	0,696807627	1,000000000

É possível notar que, ao aumentar a quantidade de atributos referentes aos superpixels, os valores do índice DICE tendem a diminuir e, em contrapartida, os valores de Erro XOR tendem a aumentar.

4. Considerações Finais

O desenvolvimento deste trabalho em andamento já possibilitou a obtenção de alguns resultados preliminares, utilizando diferentes configurações do método investigado com o intuito de explorar aspectos pouco investigados na literatura.

Especificamente, acredita-se que esses resultados possam servir de base para investigações mais aprofundadas (e.g., testes de hipótese) que permitam avaliar os impactos da supervisão no desempenho de segmentação.

Referências

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., and Süsstrunk, S. (2012). Slic superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11):2274–2282.
- Al-Masni, M. A., Al-Antari, M. A., Choi, M.-T., Han, S.-M., and Kim, T.-S. (2018). Skin lesion segmentation in dermoscopy images via deep full resolution convolutional networks. *Computer Methods and Programs in Biomedicine*, 162:221–231.
- Bernart, E., Flores, E. S., and Scharcanski, J. (2019). Macroscopic pigmented skin lesion prescreening. In Narayan, R., editor, *Encyclopedia of Biomedical Engineering*, volume 2, pages 561–573. Elsevier.
- Bissoto, A., Fornaciali, M., Valle, E., and Avila, S. (2019). (de) constructing bias on skin lesion datasets. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pages 2766–2774.
- Cavalcanti, P. G., Scharcanski, J., and Lopes, C. B. (2010). Shading attenuation in human skin color images. In *Proceedings of the International Symposium on Visual Computing (ISVC)*, pages 190–198.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., and Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *nature*, 542(7639):115–118.
- Flores, E. and Scharcanski, J. (2016). Segmentation of melanocytic skin lesions using feature learning and dictionaries. *Expert Systems with Applications*, 56:300–309.
- Glaister, J., Wong, A., and Clausi, D. A. (2014). Segmentation of skin lesions from digital images using joint statistical texture distinctiveness. *IEEE Transactions on Biomedical Engineering*, 61(4):1220–1230.
- Hasan, M. K., Dahal, L., Samarakoon, P. N., Tushar, F. I., and Martí, R. (2020). DSNet: Automatic dermoscopic skin lesion segmentation. *Computers in Biology and Medicine*, 120:103738.
- Nasr-Esfahani, E., Samavi, S., Karimi, N., Soroushmehr, S. M. R., Jafari, M. H., Ward, K., and Najarian, K. (2016). Melanoma detection by analysis of clinical images using convolutional neural network. In *International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 1373–1376.
- University of Waterloo (2013). Skin cancer detection. Disponível em: <https://uwaterloo.ca/vision-image-processing-lab/research-demos/skin-cancer-detection>. Último acesso em: 13 mar. 2023.
- Zortea, M., Flores, E., and Scharcanski, J. (2017). A simple weighted thresholding method for the segmentation of pigmented skin lesions in macroscopic images. *Pattern Recognition*, 64:92–104.