

# Segmentação Semisupervisionada de Lesões de Pele com Uso de Superpixels

Elineide Santos<sup>1</sup>, Rodrigo Veras<sup>1</sup>, Nayara Moura<sup>1</sup>

<sup>1</sup> Departamento de Computação – Universidade Federal do Piauí (UFPI)

{elineide.silva.inf, naayaraholanda}@gmail.com, rveras@ufpi.edu.br

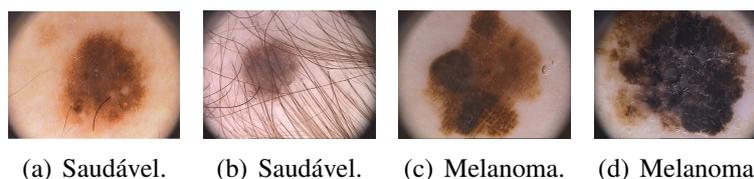
**Abstract.** *Currently, the use of images in medical examinations has become more popular as it consists of a less invasive procedure for patients. In this work a semi-automatic algorithm with the use of textit superpixels is proposed to segment skin lesions. The purpose of which is to automate the segmentation of the images, requiring only a prior appointment of some regions by the specialist physician. PH<sup>2</sup> containing exactly 200 images from public archives was the basis of our assessment. The results obtained demonstrate the applicability of our algorithm, since in the tests performed the Kappa index reached values considered "Excellent".*

**Resumo.** *Atualmente, a utilização de imagens em exames médicos tornou-se mais popular, pois consiste em um procedimento menos invasivo para os pacientes. Nesse trabalho é proposto um algoritmo semi-automático com o uso de superpixels para segmentar lesões de pele. O qual tem o como objetivo automatizar a segmentação das imagens sendo apenas necessário uma marcação prévia de algumas regiões pelo médico especialista. O PH<sup>2</sup> contendo exatamente 200 imagens de arquivos públicos foi a base da nossa avaliação. Os resultados alcançados demonstram a aplicabilidade do nosso algoritmo, visto que, nos testes realizados o índice Kappa atingiu valores considerados "Exce-lentes".*

## 1. Introdução

A pele humana é responsável pela troca de substâncias entre o organismo e o ambiente. Em consequência disso, podem surgir lesões. Essas lesões são classificadas como benignas ou malignas (Figura 1). As lesões malignas formam cânceres de pele que se proliferam em diversos tecidos do corpo humano afetando-os drasticamente. Há cerca de 120 mil novos casos por ano em todo o Brasil, sendo a maioria descoberta em estágio avançado, como é o caso do melanoma [1]. O melanoma tem origem a partir dos melanócitos que são células produtoras de melanina (pigmentação do corpo), sua forma mais comum caracteriza-se por manchas em toda a extensão da pele e a identificação em geral ocorre através de imagens analisadas por especialistas.

Os sistemas de Diagnósticos Assistidos por Computador (*Computer Assisted Diagnostics - CAD*) veem se tornando popular, pois combina a inteligência artificial com o processamento digital de imagens visando agilizar os diagnósticos na análise de imagens [2]. O monitoramento de lesões benignas, a detecção e análise de imagens com lesões malignas são exemplos da aplicação de CAD's na atualidade. Outra forma, também



**Figura 1. Exemplos de lesões de pele: (a) e (b) benignas e (c) e (d) melanomas.**

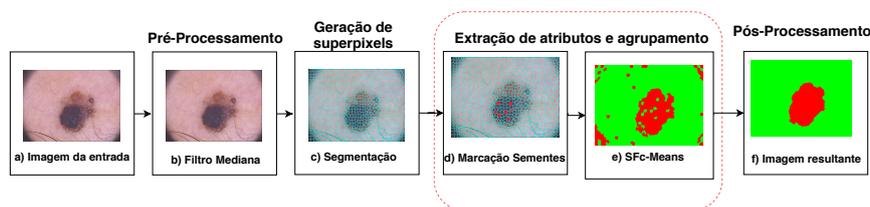
utilizada na coleta ágil dos resultados é a segmentação das imagens que diminui a complexidade das formas (linhas, curvas) e uma de suas aplicações é a identificação do melanoma em seus estágios iniciais de proliferação.

Em nosso trabalho propomos um método semi-automático (método com manuseio humano e automático) de segmentação de imagens de lesão de pele com relação ao melanoma. Esse método foi desenvolvido realizando uma análise de alguns trabalhos para a segmentação de lesões de pele, os quais utilizavam técnicas de pré-processamento e segmentação.

Segundo Oliveira et al. [3], grande parte dos trabalhos utilizaram um pré-processamento baseado na troca de sistemas de cores, ajuste de contraste [4] e suavização. Além disso, alguns estudos abordados em Silveira [5] comprovaram a eficiência dos CAD's com a utilização da segmentação e pós processamento nas imagens. Nesse estudo, os autores dividiram as avaliações e propostas em três classes com base na principal técnica de segmentação utilizada: baseada em bordas, limiarização e contorno ativo. Dentre estes, a limiarização é a mais utilizada, mas esta não garante a resolução total dos problemas de iluminação e ruídos nas imagens.

## 2. Metodologia

A segmentação de imagens de lesões de pele está dividida em quatro etapas principais onde a primeira correspondente a etapa de pré-processamento com a aplicação do filtro de mediana, a etapa dois envolve a geração de *superpixels*, em seguida, ocorre a etapa três iniciada primeiramente pela marcação das sementes e depois aplicação do *SFC-means*. Finalizando, o último quadro corresponde a etapa de pós processamento (Figura 2).



**Figura 2. Fluxograma do método proposto.**

### 2.1. Pré-processamento

No pré-processamento (Figura 2(b)) utilizamos o filtro de mediana na pele a fim de suavizar a presença de pelos ao longo da epiderme sem alterar os contornos da imagem. Este filtro é considerado um método não-linear que faz uma suavização proporcional ao tamanho da mediana da sua vizinhança de acordo com uma máscara [6]. Desse modo, a dimensão é mantida na imagem e ocorre somente o borrimento de linhas muito finas, neste caso os pelos.

## 2.2. Geração de superpixels

Uma imagem possui diversos pixels, os quais ao serem processados exigem um grande esforço computacional. Com a intenção de minimizar esse gasto de recursos propomos a utilização de *superpixels*. Os *superpixels* dividem uma imagem em clusters (grupo de pixels). Essas regiões são definidas neste trabalho utilizando dois tipos de algoritmos com o objetivo de avaliar qual possui melhor desempenho na base utilizada: o *Simple Linear Iterative Clustering (SLIC)* [7] e o *Simple Linear Iterative Clustering version with 0 parameter (SLIC0)* [8].

O SLIC (*Simple Linear Iterative Clustering*) utiliza como parâmetro uma compactação que se adapta ao tipo da região, sendo suaves em zonas leves e irregulares em zonas texturizadas, tendo como consequência a geração de quantidades de superpixels compactos e quase uniformes entre si. Já o SLIC0 (*Simple Linear Iterative Clustering With 0*) difere do SLIC, gerando imagens regulares para todas as regiões.

Em nossa proposta definimos as quantidades de *superpixels* da imagem em 400, 600, 800 e 1000 para SLIC e SLIC0. Após uma série de testes, verificamos que as divisões da imagens são mais precisas utilizando 1000 *superpixels* no SLIC e 800 no SLIC0 e optamos por aplica-las nas próximas etapas do método proposto. A Figura 2(c) corresponde a segmentação utilizando a geração de *superpixels*.

## 2.3. Extração de atributos e agrupamento

A extração de atributos presente na etapa de Extração e Agrupamento da Figura 2 é realizada a fim de obter informações de textura e cor de cada imagem. As informações de textura são retiradas utilizando a matriz de co-ocorrência de nível de cinza (*Gray-Level Co-occurrence Matrix - GLCM*) [9]. Essa matriz é gerada a partir da contagem de ocorrências de combinações entre os tons de cinzas dos *superpixels* analisados e das informações de textura. As informações de cores são tonalidade e saturação do modelo de cores HSV e os três canais do modelo de cores RGB (vermelho, verde e azul).

Na GLCM As probabilidades de co-ocorrências são calculadas entre dois níveis de cinza  $j$  e  $k$ , dada uma certa distância  $s$  (também conhecida como *pps* ou *pixel pair spacing*) e uma orientação  $\theta$  (theta) ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  ou  $135^\circ$ ). Em Haralick estabeleceu-se 14 características significativas calculadas a partir da matriz GLCM, nesse trabalho só utilizamos cinco, sendo elas: contraste, correlação, energia, homogeneidade e a entropia. Elas foram calculadas para cada grupo de canal dos modelos de cores RGB + HS (90 atributos) da imagem segmentada. Além disso, com exceção da entropia apenas na orientação  $0^\circ$ , todas as características extraídas foram calculadas para todas as orientações da matriz.

Em seguida, o agrupamento dos *superpixels* é feito, inicialmente marcando manualmente as regiões segmentadas por um médico dermatologista para serem usadas sementes. As sementes são amostras rotuladas inicialmente, cujo objetivo é realizar o aprendizado não-supervisionado, e a partir disso, rotular as demais amostras. Elas são importantes para indicar ao *superpixel* o tipo de região a qual ele deve se agrupar (Figura 2(d)). No melanoma, as regiões são divididas em fundo e lesão. Logo depois, aplicamos o algoritmo proposto por Santos et al. [10], chamado *SFC-means*, um algoritmo de agrupamento semisupervisionado (necessita de poucas amostras rotulados) baseado no *Fuzzy C-means*. Os dois algoritmos se diferem principalmente pelo o uso de todos os exemplos rotulados disponíveis (sementes), que ocorrem apenas no *SFC-means* (Figura 2(e)).

## 2.4. Pós-processamento

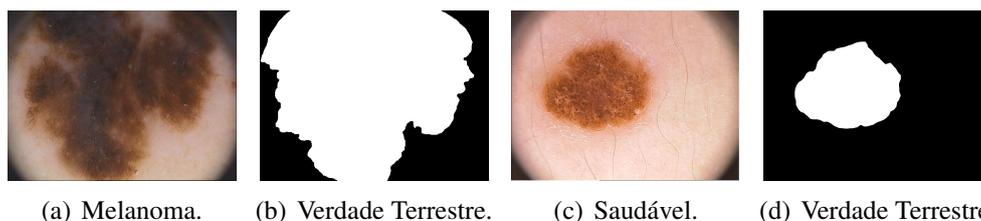
Na imagem resultante aplicamos o processo de pós-processamento visando preencher as regiões fragmentadas após o *SFc-means*. Nessa etapa, aplicamos inicialmente as operações da morfologia matemática. A dilatação e a erosão são as operações fundamentais da morfologia matemática, sendo a dilatação responsável por unir os fragmentos próximos e a erosão pela separação dos fragmentos distantes.

A operação de abertura, também faz parte da morfologia matemática, consiste em erodir e depois dilatar com o objetivo de eliminar partículas indesejáveis (fragmentos). Dessa forma, definimos o uso de uma operação de abertura seguida de uma erosão com um elemento de raio de 0,5 % da quantidade de linhas da imagem.

Ainda, selecionamos a partícula com maior tamanho como região correspondente a lesão e usamos a técnica de contorno ativo para definir precisamente os limites das áreas consideradas como lesão na imagem. Na Figura 2 na etapa de pós-processamento (Figura 2(f)) é possível observar a aplicação do método, observe a região na cor vermelha, correspondente a lesão, é separada dos fragmentos menores com a erosão. Em seguida são preenchidas as suas regiões fragmentadas por meio da dilatação, selecionados o maior fragmento e então o contorno ativo é aplicado.

## 3. Base de imagens

A segmentação de imagens é um grande desafio, principalmente porque as imagens das bases podem sofrer variações como baixo contraste, iluminação inconstante e presença de ruídos. Com a finalidade de superar essas delimitações propomos o algoritmo semi-supervisionado que foi testado em uma base PH<sup>2</sup> [11] de dados públicos de 200 imagens de lesão de pele, dentre elas, 160 saudáveis e 40 melanomas provenientes de exames médicos. Todas as imagens possuem suas verdades terrestres (marcações médicas). Alguns exemplos de melanoma e lesões benignas podem ser vistos na Figura 3.



(a) Melanoma. (b) Verdade Terrestre. (c) Saudável. (d) Verdade Terrestre.

**Figura 3. Exemplos de bases com suas verdades terrestre.**

Nesse exemplo, a imagem é dividida entre fundo (preto) e lesão (branco) da pele como mostrado em Figura 3(b) e Figura 3(d).

## 4. Resultados e Discussões

Para realizarmos uma avaliação do método proposto, utilizamos os valores obtidos através da matriz de confusão para determinar as métricas da literatura. A partir da matriz, obtivemos quatro valores através da comparação *pixel a pixel* da verdade terrestre e da imagem segmentada. Esses valores são denominados: Verdadeiro positivo (VP), Falso Positivo (FP), Falso Negativo (FN) e Verdadeiro Negativo (VN). Com essas informações são calculados a Acurácia (A), Jaccard (J), Especificidade (E), Sensibilidade (S), Precisão (P) e o F-Score (FS) das imagens.

O índice Kappa (K) também é calculado, porém, este leva em consideração todos os elementos da matriz de confusão. De acordo com Landis e Koch [12], o K assume valores entre 0 e 1. O resultado é qualificado de acordo com o K da seguinte maneira:  $K \leq 0,2$ : Pobre;  $0,2 < K \leq 0,4$ : Moderado;  $0,4 < K \leq 0,6$ : Bom;  $0,6 < K \leq 0,8$ : Muito bom;  $K > 0,8$ : Excelente.

Nesse trabalho, a segmentação foi aplicada em um banco de dados público com 200 imagens de lesão de pele da base PH<sup>2</sup>. As Tabelas 1 e 2 apresentam os resultados de segmentação obtidos pelo método proposto com a aplicação das métricas. Dividimos as imagens de três formas: todas as imagens (Geral), lesões benignas (Saudáveis) e lesões malignas (Melanoma).

**Tabela 1. Desempenho da segmentação do método proposto utilizando SLIC com 1000 *superpixels*.**

Base	A(%)	J(%)	E(%)	S(%)	P(%)	FS(%)	K
Geral	95,94	86,85	93,79	91,92	94,27	92,66	0,87
Saudáveis	97,18	87,42	97,57	92,13	94,77	93,14	0,91
Melanoma	91,48	87,34	77,30	94,50	92,10	93,15	0,71

A Tabela 1 mostra os resultados obtidos utilizando o método SLIC com 1000 *superpixels*, estes valores foram os melhores resultados segundo a Acurácia e índice Kappa dentre todas as quantidades de *superpixels* analisadas. Observe que o Kappa obteve resultados melhores nas imagens saudáveis, pois possuem complexidade inferior às de melanoma, devido apresentarem bordas homogêneas.

**Tabela 2. Desempenho da segmentação do método proposto utilizando SLIC0 com 600 *superpixels*.**

Base	A(%)	J(%)	E(%)	S(%)	P(%)	FS(%)	K
Geral	95,60	82,09	96,60	88,00	93,17	89,03	0,87
Saudáveis	95,79	82,71	96,59	88,72	93,12	89,42	0,87
Melanoma	89,64	84,84	72,92	94,18	89,76	91,68	0,67

A Tabela 2 mostra os resultados do método SLIC0. Nela também são utilizados as mesmas configurações do método SLIC, também possuem resultados superiores para imagens saudáveis.

Nesse contexto, podemos observar que os melhores valores para cada base do método SLIC0, com exceção do geral, são inferiores ao SLIC. Neste caso, o melhor desempenho na base PH<sup>2</sup> segundo a índice Kappa é utilizando o método SLIC cujo os resultados foram excelentes demonstrando uma correta segmentação dos *superpixels*.

## 5. Conclusão

Nos sistemas CAD a etapa de segmentação é indispensável para um diagnóstico adequado nos exames dos pacientes. Com base nisso, nosso trabalho apresentou um algoritmo semisupervisionado o qual pode ser um importante aliado nessa segmentação. É necessário apenas o uso de alguns pixels de cada região (sementes) para permitir o agrupamento proposto, sendo este baseado no SFC-means.

Como foi abordado, as imagens primeiramente passaram por um pré-processamento com o filtro de mediana, em seguida os resultados foram agrupados com o SFC-means e obtiveram acertos significativos, estando a maioria com índices apontados como excelentes. Também foram utilizadas técnicas de pós-processamento como morfologia matemática e contorno ativo com o intuito de preencher regiões não segmentadas.

A fim de melhorar os resultados do algoritmo proposto, pretendemos expandir as análises sobre a detecção e retirada de pelos das amostras. Além disso, as informações como o diâmetro das regiões serão utilizados no pós-processamento.

## Referências

- [1] INCA, “Tipo - pele melanoma,” [http://www.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/pele\\_melanoma](http://www.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/pele_melanoma), 2018, acessado em: 2018.
- [2] M. E. C. Jacob Scharcanski, in *Computer Vision Techniques for the Diagnosis of Skin Cancer*. Springer, 2013.
- [3] R. B. Oliveira, M. E. Filho, Z. Ma, J. P. Papa, A. S. Pereira, and J. M. R. Tavares, “Computational methods for the image segmentation of pigmented skin lesions: A review,” *Computer Methods and Programs in Biomedicine*, vol. 131, pp. 127–141, 2016.
- [4] A. Pennisi, D. D. Bloisi, D. Nardi, A. R. Giampetruzzi, C. Mondinoc, and A. Facchiano, “Skin lesion image segmentation using delaunay triangulation for melanoma detection,” *Computerized Medical Imaging and Graphics*, vol. 52, pp. 89–103, 2016.
- [5] J. S. M. Margarida Silveira, Jacinto C. Nascimento, “Comparison of segmentation methods for melanoma diagnosis in dermoscopy images, ieee.” *Sel. Top. Signal Processing* 3, 2009, pp. 929–936.
- [6] R. C. GONZALEZ and R. E. WOODS, *Digital image processing*, 2nd ed. New Jersey: Prentice Hall, 2002.
- [7] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk, “Slic superpixels compared to state-of-the-art superpixel methods,” *Transactions on Pattern Analysis and Machine Intelligence*, vol. 34, no. 11, pp. 2274–2282, 2012.
- [8] Z. C. M. B F Nan, “Slico-based superpixel segmentation method with texture fusion,” *Chinese Journal of Scientific Instrument*, vol. 35, no. 3, pp. 527–534, 2014.
- [9] R. M. Haralick, K. Shanmugam *et al.*, “Textural features for image classification,” *IEEE Transactions on systems, man, and cybernetics*, vol. 3, no. 6, pp. 610–621, 1973.
- [10] L. Santos, R. Veras, R. Rabelo, K. Aires, and O. Aires, “A seeded fuzzy c-means based approach to automatic cup-to-disc ratio measurement,” in *Systems, Man, and Cybernetics (SMC), 2017 IEEE International Conference on*. IEEE, 2017, pp. 1075–1080.
- [11] T. Mendonça, P. M. Ferreira, J. S. Marques, A. R. Marcal, and J. Rozeira, “Ph2-a dermoscopic image database for research and benchmarking,” in *Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE*. IEEE, 2013, pp. 5437–5440.
- [12] J. R. Landis and G. G. Koch, “The measurement of observer agreement for categorical data,” *biometrics*, pp. 159–174, 1977.