

GABRIEL LANA NASCIMENTO BARROS

Orientador: Jadson Castro Gertrudes
Co-orientadora: Roberta Barbosa Oliveira

**COMPARAÇÃO DE TÉCNICAS DE REMOÇÃO DE PELOS
PARA SEGMENTAÇÃO DE LESÕES DE PELE EM
IMAGENS DERMATOSCÓPICAS**

Ouro Preto
Abril de 2021

UNIVERSIDADE FEDERAL DE OURO PRETO
INSTITUTO DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

**COMPARAÇÃO DE TÉCNICAS DE REMOÇÃO DE PELOS
PARA SEGMENTAÇÃO DE LESÕES DE PELE EM
IMAGENS DERMATOSCÓPICAS**

Monografia apresentada ao Curso de Bacharelado em Ciência da Computação da Universidade Federal de Ouro Preto como requisito parcial para a obtenção do grau de Bacharel em Ciência da Computação.

GABRIEL LANA NASCIMENTO BARROS

Ouro Preto
Abril de 2021



FOLHA DE APROVAÇÃO

Gabriel Lana Nascimento Barros

Comparação de técnicas de remoção de pelos para segmentação de lesões de pele em imagens dermatoscópicas

Monografia apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Ciência da Computação

Aprovada em 19 de Abril de 2021.

Membros da banca

Jadson Castro Gertrudes (Orientador) - Doutor - Universidade Federal de Ouro Preto
Roberta Barbosa de Oliveira (Coorientadora) - Doutora - Universidade de Brasília
Eduardo José da Silva Luz (Examinador) - Doutor - Universidade Federal de Ouro Preto
Guillermo Camara Chavez (Examinador) - Doutor - Universidade Federal de Ouro Preto

Jadson Castro Gertrudes, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 19/04/2021.



Documento assinado eletronicamente por **Jadson Castro Gertrudes**, **PROFESSOR DE MAGISTERIO SUPERIOR**, em 28/04/2021, às 13:45, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0160356** e o código CRC **7B9450F7**.

Resumo

A presença de pelos em imagens dermatoscópicas pode afetar negativamente a acurácia de algoritmos de diagnóstico de lesões de pele tanto na segmentação da lesão, como na extração de características da mesma. Por esta razão, aplicar métodos de remoção de pelos como um pré-processamento se mostra interessante, já que a extração de pelos pode contribuir para um melhor resultado dos algoritmos de classificação de lesões de pele. No presente trabalho, diferentes técnicas de detecção de pelos e de restauração de imagens dermatoscópicas são apresentadas. O objetivo deste trabalho é comparar técnicas de remoção de pelos para segmentação de lesões de pele em imagens dermatoscópicas, a fim de verificar se estas técnicas melhoram o resultado da segmentação e quais são as melhores técnicas. Para isso ser realizado, foi proposta uma metodologia para realização do trabalho, onde primeiramente será efetuada a remoção de pelos na imagem de entrada, em seguida a lesão na imagem será segmentada e finalmente o resultado da segmentação será comparado com o *ground-truth* e avaliado por métricas tais como, acurácia, sensibilidade, especificidade, índice de similaridade de Jaccard e coeficiente de Dice. Com os resultados obtidos neste trabalho, pode-se concluir que a remoção de pelos melhora a segmentação de lesões em imagens dermatoscópicas, já que os resultados das métricas aplicadas foram melhores no conjunto de imagens onde a remoção de pelos foi utilizada, tendo como melhor método de remoção de pelos o *inpainting* baseado em exemplos, utilizando a operação generalizada de fechamento com aprimoramento da máscara binário de pelos gerada. A acurácia, sensibilidade e especificidade deste método foram de 0,87693, 0,78265 e 0,93842 respectivamente, para o conjunto de imagens com pelos e de 0,87262, 0,82440 e 0,91256 respectivamente para o conjunto de imagens sem pelos.

Palavras-chave: Pré-processamento de imagens, detecção de pelos, remoção de pelos, segmentação de lesões de pele, imagens dermatoscópicas.

Abstract

The presence of hair in dermoscopic images may negatively affect the accuracy of skin lesion classification algorithms in lesion segmentation and skin feature extraction. Therefore, applying hair removal methods as a preprocessing step is possibly beneficial, as hair extraction may contribute to a better outcome of skin lesion classification algorithms. In this study, different hair detection and restoration techniques for dermoscopic images are explored. The objective of this work is to compare hair removal techniques for segmentation of skin lesions in dermoscopic images to verify whether these techniques improve the result of the segmentation, and which are the best techniques to be applied. The methodology utilized in the study consisted of applying hair removal techniques on the input image; then, the lesion in the image is segmented; finally, the result of the segmentation will be compared with the ground-truth and evaluated using metrics such as accuracy, sensitivity, specificity, Jaccard similarity index, and Dice coefficient. Based on the results of this work, conclusions can be drawn that hair removal improves the segmentation of lesions in dermoscopic images, for the results of the applied metrics were better in the set of images where hair removal techniques were applied. The best hair removal technique found was the exemplar based inpainting method with the enhanced binary hair mask generated by the generalized closing operation as its input. The accuracy, sensibility and specificity of this method were 0,87693, 0,78265 and 0,93842, respectively, for the set of images with hair, and 0,87262, 0,82440 and 0.91256, respectively, for the set of images without hair.

Keywords: Hair removal, hair segmentation, hair detection, dermoscopic images, lesion segmentation.

Sumário

1	Introdução	1
1.1	Justificativa	3
1.2	Objetivos Geral e Específicos	3
1.3	Organização do Trabalho	3
2	Revisão de Literatura	5
3	Fundamentação Teórica	10
3.1	Pré-processamento de imagens	10
3.1.1	Detecção de bordas	10
3.1.2	Operações morfológicas	12
3.1.3	Restauração de imagem	16
3.1.4	Suavização de imagem	17
3.2	Segmentação de imagem	18
3.2.1	Limiarização	19
3.2.2	Crescimento de regiões	19
3.3	Espaço de cores	21
3.3.1	Espaço de cores RGB	21
3.3.2	Espaço de cores YIQ	21
3.4	Métricas de avaliação	22
4	Metodologia	24
4.1	Remoção de pelos	24
4.1.1	Detecção de pelos	24
4.1.2	Aprimoramento das máscaras	26
4.1.3	Restauração da imagem	26
4.2	Segmentação da lesão	26
5	Experimentos Computacionais	28
5.1	Base de imagens	28

5.2 Experimentos realizados	29
5.3 Resultados	30
5.3.1 Segmentação da lesão sem remoção de pelos	30
5.3.2 Segmentação da lesão com remoção de pelos: substituição pelo vizinho mais próximo	31
5.3.3 Segmentação da lesão com remoção de pelos: <i>inpainting</i> baseado em exemplos	33
6 Conclusão	37
Referências Bibliográficas	39

Lista de Figuras

1.1	Quatro exemplos de imagens com artefatos: (a) Pelos e adesivo, (b) bolhas de gel, (c) marcações e régua, e (d) uma lesão obstruída por pelos (Tschandl et al., 2018).	2
3.1	Resultado da aplicação do operador de Sobel: (a) Imagem original (1024×768), (b) imagem binária com as bordas detectadas em branco.	11
3.2	Resultado da aplicação do filtro de Prewitt: (a) Imagem original (1024×768) e (b) imagem binária com as bordas detectadas em branco.	12
3.3	Resultado da aplicação da dilatação em uma imagem binária (1024×768): (a) Imagem após a aplicação do operador Sobel demonstrada na Figura 3.1 e (b) imagem após a dilatação.	13
3.4	Resultado da aplicação da erosão em uma imagem binária (1024×768): (a) Imagem após a operação de dilatação demonstrada na Figura 3.3 e (b) imagem após a erosão.	14
3.5	Resultado da aplicação da operação de fechamento em uma imagem binária (1024×768): (a) Imagem após a aplicação do operador Sobel demonstrada na Figura 3.1 e (b) imagem após a operação de fechamento.	15
3.6	Resultado da aplicação da operação de abertura em uma imagem binária (1024×768): (a) Imagem após a operação de dilatação demonstrada na Figura 3.3 (b) imagem após a operação de abertura.	15
3.7	Resultado da aplicação da operação <i>top-hat</i> de fechamento: (a) Imagem original (1024×768) e (b) imagem binária resultante da operação.	16
3.8	Influência do tamanho da máscara do filtro de média: (a) Imagem original (1024×768), (b) máscara 10×10 e (c) máscara 20×20	18
3.9	Resultado da influência do tamanho da janela do filtro da mediana: (a) Imagem original (1024×768), (b) janela 10×10 e (c) janela 20×20	18
3.10	Aplicação do método de segmentação de Otsu: (a) Imagem original (1022×767), (b) região segmentada pelo método de Otsu.	20
3.11	Aplicação de um método de segmentação baseado em crescimento de regiões: (a) Imagem original (1022×767), (b) região segmentada pelo método de contorno ativo sem bordas.	21
3.12	Espaço de cores RGB representado na forma de um cubo (Cunha, A. L., 2016).	22

4.1 Fluxograma da metodologia proposta.	25
5.1 Quatro exemplos de imagens dermatoscópicas da base de dados do ISIC 2018: (a) e (b) imagens com pelos, e (c) e (d) imagens sem pelos (Codella et al., 2018).	29
5.2 Aplicação do método de remoção de pelos utilizando a substituição pelo vizinho mais próximo: (a) Imagem original, (b) imagem após a remoção dos pelos.	31
5.3 Aplicação do método de remoção de pelos utilizando o <i>inpainting</i> baseado em exemplos: (a) Imagem original, (b) imagem após a remoção dos pelos.	34

Lista de Tabelas

2.1	Taxa de erro médio antes e depois da remoção de pelos proposta por Xie et al. (2009) para cada método de segmentação.	7
2.2	Taxa de erro médio da segmentação depois da remoção de pelos.	8
2.3	Resultados da detecção e remoção de pelos obtidos pelo algoritmo de Zaqout (2017).	9
5.1	Resultados das métricas de avaliação para a segmentação da lesão sem a remoção de pelos.	31
5.2	Resultados das métricas de avaliação para a segmentação da lesão com inpainting por substituição pelo vizinho mais próximo.	32
5.3	Tempos de execução dos experimentos realizados utilizando inpainting por substituição pelo vizinho mais próximo.	33
5.4	Resultados das métricas de avaliação para a segmentação da lesão com inpainting baseado em exemplos.	35
5.5	Tempos de execução dos experimentos realizados utilizando inpainting baseado em exemplos.	36

Lista abreviaturas e siglas

ACC Acurácia. [22](#)

CAD *Computer-aided diagnosis*. [1](#)

CIE *Commission internationale de l'éclairage*. [8](#)

DSC Coeficiente de Dice. [23](#)

FN Falso negativo. [22](#)

FP Falso positivo. [22](#)

ISIC *International skin imaging collaboration*. [28](#)

J Índice de similaridade de Jaccard. [23](#)

NTSC *National Television Standards Committee*. [21](#)

PCA *Principal component analysis*. [7](#)

PDE *Partial differential equations*. [6](#)

RGB *Red green blue*. [v](#), [5](#), [21](#), [22](#), [25](#), [28](#)

ROI *Region of interest*. [2](#), [22](#), [23](#)

SE Sensibilidade. [23](#)

SP Especificidade. [23](#)

VN Verdadeiro negativo. [22](#)

VP Verdadeiro positivo. [22](#)

Capítulo 1

Introdução

O câncer de pele é o tipo de câncer mais frequente e corresponde a 30% de todos tumores malignos no Brasil. Estima-se cerca de 165.580 novos casos da doença no Brasil, com mais de 1.900 fatalidades (INCA, 2018). Se não tratado, o câncer de pele pode deixar, por exemplo, mutilações bastante expressivas mas quando detectado e tratado precocemente, apresenta altos percentuais de cura.

Um sistema que vem sendo utilizado para agilizar o diagnóstico de doenças em geral, incluindo o câncer de pele, é o diagnóstico auxiliado por computador (*Computer-Aided Diagnosis* - CAD). CAD auxilia médicos na interpretação de imagens médicas, como uma ferramenta a fim de obter uma "segunda opinião". Portanto, o diagnóstico final sempre é do médico. Como o diagnóstico final de uma lesão de pele pode variar de acordo com o médico que a analisou, o CAD pode ajudar a reduzir ambiguidades e melhorar a acurácia dos diagnósticos (Azevedo-Marques, 2001).

A dermatoscopia é um tipo de exame utilizado para diagnosticar o câncer de pele. Ela se utiliza de um aparato denominado dermatoscópio que amplia a aparência da lesão, no mínimo, 10 vezes. Este aparato é utilizado para visualizar camadas da pele não vistas a olho nu, assim amplificando a acurácia do diagnóstico do câncer. Portanto, a dermatoscopia tem papel fundamental no diagnóstico precoce do câncer de pele (Rezze et al., 2006; INCA, 2018).

Algoritmos de diagnóstico automático de lesões de pele pigmentada geralmente consideram diversas características nas lesões presentes na imagem dermatoscópica (Abbas et al., 2013a; Møllersen et al., 2015; Maglogiannis e Delibasis, 2015). Para se realizar o diagnóstico da lesão, geralmente são analisadas algumas características da mesma como, assimetria, borda, cor e estruturas diferenciais. Estas características são internacionalmente conhecidas como a regra ABCD. Analisando estas características, quando identificado certas particularidades das mesmas presentes ou não na lesão, pode vir a ser um câncer melanoma (Johr, 2002).

Uma imagem dermatoscópica pode conter muitos ruídos ou artefatos, como por exemplo pelos, adesivos, bolhas de gel, marcações e régua, como podem ser observados na Figura 1.1. A presença destes ruídos podem afetar a acurácia da identificação da região de interesse

(*Region Of Interest* - ROI) em algoritmos de segmentação e classificação de lesões de pele. Neste caso, a ROI é a lesão na imagem e estes ruídos podem ser identificados como parte da lesão ou impedir que parte da mesma seja identificada. Além disso, a presença de artefatos pode interferir na extração de características da lesão. Pelos localizados em cima da lesão pode afetar a extração da característica de cor, por exemplo, uma vez que a cor dos pelos seria extraída, e não da lesão. A presença de pelos contornando as bordas da lesão também pode causar uma segmentação errada da lesão, já que o pelo pode ser identificado como sendo a borda da lesão. Então, a remoção de artefatos e ruídos em imagens dermatoscópicas pode ser importante para algoritmos de segmentação e extração de características de lesões de pele.




Figura 1.1: Quatro exemplos de imagens com artefatos: (a) Pelos e adesivo, (b) bolhas de gel, (c) marcações e régua, e (d) uma lesão obstruída por pelos (Tschandl et al., 2018).

Um dos primeiros trabalhos relacionados à remoção de pelos foi um algoritmo denominado DullRazor, proposto por Lee et al. (1997), que utiliza morfologia para detectar os pelos e um passo de interpolação para removê-los. Na literatura, além da morfologia (Bibiloni et al., 2017; Xie et al., 2009; Schmid-Saugeona et al., 2003), várias outras técnicas são utilizadas como detectores de borda (Kiani e Sharafat, 2011; Toossi et al., 2013) e derivadas Gaussianas (Abbas et al., 2011). Assim como para a detecção de pelos, além da a interpolação linear (Nguyen et al., 2010; Lee et al., 1997), diferentes técnicas podem ser utilizadas para remover os mesmos, tais como técnicas baseadas em equações diferenciais parciais (Xie et al., 2009) e *coherence transport* (Abbas et al., 2011; Toossi et al., 2013).

Devido à diversidade de técnicas apresentadas na literatura para solucionar o problema de remoção de pelos, o presente trabalho tem como objetivo avaliar métodos de remoção de pelos compostos de combinações de algumas destas técnicas. Com isso, espera-se definir se a remoção de pelos contribui para uma melhor segmentação de lesões de pele em imagens dermatoscópicas, e se isso for confirmado, quais destes métodos são os melhores.

1.1 Justificativa

Segundo o Instituto Nacional de Câncer (INCA), estima-se mais de 165.000 casos de câncer de pele apenas no Brasil e quando detectado precocemente, apresenta altos percentuais de cura (INCA, 2018). A utilização de sistemas CAD vem aumentando cada vez mais e com isso cresce o interesse por algoritmos mais rápidos e precisos (Perrinaud et al., 2007; Dreiseitl et al., 2009; Cheng et al., 2016). A precisão de algoritmos que tratam de problemas médicos é primordial, visto que o diagnóstico automático pode auxiliar na decisão de um médico que, conseqüentemente, afeta o tratamento de um paciente.

A presença de artefatos em imagens pode interferir na acurácia dos resultados obtidos por algoritmos de segmentação e classificação de lesões de pele (Abbas et al., 2013a,b). Por esta razão, a remoção de pelos em imagens dermatoscópicas pode ser importante para tais algoritmos. Logo, a remoção de pelos quando aplicada em uma imagem que será processada por um algoritmo tradicional de classificação de lesões de pele, pode proporcionar uma maior probabilidade de um diagnóstico mais preciso, já que a identificação correta da região da lesão facilita o processo de classificação. Com isso, pode-se concluir que a remoção de pelos pode vir a ser uma parte fundamental para que classificadores de lesões de pele proporcionem um diagnóstico correto.

1.2 Objetivos Geral e Específicos

O objetivo geral deste trabalho é comparar diferentes técnicas de remoção de pelos em imagens dermatoscópicas. Os objetivos específicos deste trabalho são:

- Analisar quais técnicas de remoção de pelos proporcionaram uma melhor segmentação da lesão, através das métricas de avaliação;
- Analisar a influência da remoção de pelos na segmentação de lesões de pele em imagens dermatoscópicas.

1.3 Organização do Trabalho

Este trabalho é organizado da seguinte forma: no Capítulo 2, são apresentados trabalhos relacionados à remoção de pelos em imagens dermatoscópicas. Nele é feita uma breve descrição

das técnicas utilizadas nestes trabalhos, juntamente com a apresentação dos resultados dos mesmos. No Capítulo [3](#), são apresentadas técnicas de processamento de imagens, como detecção de bordas, suavização, espaço de cores e segmentação, bem como métricas de avaliação. No Capítulo [4](#), é apresentada a metodologia do trabalho. No Capítulo [5](#), são apresentados os experimentos realizados no trabalho, a base de imagens utilizada e os resultados a partir da avaliação das métricas. Finalmente, no Capítulo [6](#), é apresentada a conclusão obtida após a pesquisa realizada neste trabalho.

Capítulo 2

Revisão de Literatura

Como mencionado no Capítulo [1](#), a remoção de pelos em imagens dermatoscópicas pode ser fundamental para algoritmos de segmentação e classificação de lesões de pele. A presença de ruídos, como pelos, pode afetar a acurácia deste algoritmos. Logo diversos métodos para a remoção de pelos já foram propostos na literatura. Os métodos de remoção de pelos têm como objetivo remover todos os pelos presentes na imagem, independentemente de suas características, tais como espessura, coloração e diferentes orientações. Além disso, eles buscam introduzir o mínimo possível de novos ruídos na imagem, já que seus objetivos são justamente reduzir os ruídos presentes na imagem.

O algoritmo DullRazor, desenvolvido por [Lee et al. \(1997\)](#), tem como objetivo a remoção de pelos escuros e grossos, diferentemente de trabalhos mais recentes que buscam remover todos os tipos de pelos ([Pathan et al., 2018](#)). Este algoritmo é dividido em três passos: a detecção dos *pixels* que correspondem aos pelos, a substituição destes *pixels* por *pixels* que não são pelos e a suavização do resultado final do passo anterior. Ele foi desenvolvido apenas para imagens [RGB](#), que é um sistema de cores aditivas onde R (*red*) representa a cor vermelha, G (*green*) a cor verde e B (*blue*) a cor azul. Então, dada uma imagem no sistema de cores RGB, a detecção dos pelos é realizada através da aplicação de uma operação morfológica generalizada de fechamento sobre a escala de cinza de cada banda da imagem de entrada, gerando uma máscara binária. Como esta máscara contém algumas regiões que não são pelos, é realizada a interpolação apenas nas regiões cujo maior eixo é maior que 50 *pixels* e os eixos restantes são menores que 10 *pixels*. Na interpolação, os valores dos *pixels* que foram detectados como pelos são então substituídos pelos valores dos *pixels* mais próximos que não foram detectados como pelos. Por último, foi aplicado um filtro de mediana na imagem final a fim de suavizar as bordas das regiões interpoladas.

Utilizando o algoritmo proposto por [Lee et al. \(1997\)](#), ainda foi possível ver traços de pelos que não foram propriamente removidos nas imagens resultantes do algoritmo. Além disso o passo de interpolação deste algoritmo não foi eficaz, já que em muitos casos foi possível visualizar as bordas das regiões interpoladas. O E-shaver é um algoritmo proposto por [Kiani](#)

e Sharafat (2011) como um aprimoramento do DullRazor (Lee et al., 1997). O aprimoramento proposto foi, além de remover pelos grossos e escuros como proposto pelo DullRazor, também remover pelos claros e reduzir locais brancos, geralmente introduzidos pela aplicação de gel ou óleo sobre a pele. Para a detecção de pelos, foram utilizados dois filtros. O primeiro foi o filtro de Prewitt e o segundo foi proposto por Kiani e Sharafat (2011), que é obtido a partir do primeiro filtro, através da replicação de suas colunas.

Para a interpolação, Kiani e Sharafat (2011) criaram uma cópia da imagem de entrada onde o *pixels* correspondentes aos pelos são substituídos pela média dos valores em escala de cinza do *background*. Com isso, os *pixels* que correspondem aos pelos foram retirados desta imagem cópia e foram inseridos na imagem de entrada. Por último, foi aplicado um filtro de média para reduzir as marcas de bordas deixadas pelo passo de remoção. Para avaliar o desempenho do E-shaver, foi utilizado 50 imagens dermatoscópicas para compará-lo com o algoritmo DullRazor (Lee et al., 1997). Segundo Kiani e Sharafat (2011), um bom método de remoção de pelos reduz o número de *pixels* escuros e aumenta os *pixels* de nível de cinza médio. Portanto, as comparações foram realizadas através de uma métrica baseada na diferença absoluta normalizada dos histogramas para cada nível de cinza na imagem de saída de cada método com o da imagem principal. O E-shaver obteve resultados melhores de acordo com esta métrica e foi cerca de 7 vezes mais rápido que o DullRazor.

Existem também trabalhos que usam técnicas de detecção de curvas para determinar quais *pixels* são pelos (Bibiloni et al., 2017; Zhou et al., 2008). Zhou et al. (2008), por exemplo, apresentaram um sistema que detecta e remove automaticamente artefatos curvilíneos em imagens dermatoscópicas. Dada uma imagem dermatoscópica como entrada, este sistema gera uma imagem de diferença de luminância (Schmid-Saugeona et al., 2003) para realçar estruturas finas e escuras presentes na imagem. Então, foi aplicado um algoritmo de detecção de pontos de linhas, proposto por Steger (1998). Contudo, devido aos ruídos presentes na imagem, o passo que liga os pontos em segmentos de linha falha em ligar todos os pontos, logo se fez necessário um passo extra para que estes pontos fossem conectados. Finalmente, um método de *inpainting* baseado em exemplos foi aplicado. O algoritmo proposto por Zhou et al. (2008) foi testado em 460 imagens dermatoscópicas das quais 1/8 continham artefatos visíveis. Foi realizada uma comparação visual deste algoritmo proposto com o utilizado por Schmid-Saugeona et al. (2003), e segundo Zhou et al. (2008) seu algoritmo alcançou resultados visivelmente mais satisfatórios.

Técnicas de *inpainting* baseadas em equações diferenciais parciais (*Partial Differential Equations* - PDE) também podem ser utilizadas para remoção de pelos, já que uma de suas características é a preservação das características das regiões onde são aplicadas. Xie et al. (2009) propuseram um algoritmo de remoção de pelos que utiliza *inpainting* baseado em PDE. Nele os pelos na imagem foram realçados a partir de uma operação morfológica *top-hat* baseada em fechamento. Então, uma máscara binária contendo regiões prováveis de pelos foi

obtida a partir de uma técnica de segmentação baseada em estatísticas de probabilidade. Este algoritmo utilizou a função *elongate* em regiões conectadas como uma medida para remover os pelos da imagem. Após efetuada a remoção dos pelos, foi utilizada uma técnica de *inpainting* baseada em PDE, para realizar a difusão de informações da imagem através das diferenças entre *pixels*. Estes métodos são utilizados para a restauração de regiões pequenas, logo são adequados para restaurar regiões nas quais pelos foram removidos.

Para os experimentos do trabalho de Xie et al. (2009), foram selecionadas 40 imagens sem pelos para testar e calcular a taxa de *pixels* que não são pelos extraídos pelo algoritmo e dos *pixels* extraídos por este algoritmo, 0,3% não eram pelos. Também foi realizado uma comparação do passo de detecção deste algoritmo com o DullRazor (Lee et al., 1997). Foram utilizadas outras 40 imagens, com pelos, e que possuem *ground-truth* da região dos pelos produzido por um especialista. Este algoritmo apresentou uma taxa de 18% de erro, enquanto o DullRazor obteve uma taxa de erro de 30,7% no passo de detecção. Para calcular o erro na segmentação da lesão, foram utilizadas 40 imagens com o *ground-truth* também produzido por um especialista. Xie et al. (2009) aplicaram os métodos de segmentação de Otsu, *k-means* e *fuzzy c-means* nas imagens antes e depois da remoção dos pelos. Como pode ser observado na Tabela 2.1, a taxa de erro de todos os métodos foi reduzida quando aplicado o algoritmo de remoção de pelos nas imagens antes de a segmentação ser efetuada.

Tabela 2.1: Taxa de erro médio antes e depois da remoção de pelos proposta por Xie et al. (2009) para cada método de segmentação.

	Métodos de segmentação		
	Otsu (%)	<i>k-means</i> (%)	<i>Fuzzy c-means</i> (%)
Antes da remoção	16,6	15,5	15,7
Depois da remoção	11,9	14,2	14,4

Toossi et al. (2013) apresentaram um algoritmo para a remoção de pelos que utiliza a análise de componentes principais (*Principal Component Analysis* - PCA) para melhorar o contraste da imagem e facilitar o processo de segmentação dos pelos. Depois disso, é aplicado o filtro de Wiener de dimensão 3×3 para a remoção de alguns ruídos. Neste algoritmo, as fronteiras dos pelos são obtidas através do detector de bordas adaptativo de Canny. Após este passo, é utilizada uma operação morfológica na imagem contendo as bordas detectadas para segmentar as fronteiras. Após detectadas as regiões dos pelos, foi proposto por Toossi et al. (2013) um método multi resolução de *inpainting* para imagens dermatoscópicas, baseada em *coherence transport* (Bornemann e März, 2007). Este método utiliza uma estrutura baseada em *wavelet* para reparar a imagem. O método proposto por Toossi et al. (2013) para detecção e reparação foi testado em 50 imagens dermatoscópicas, e obteve uma acurácia de 88,3%, enquanto o DullRazor (Lee et al., 1997) obteve 48,6%. Foram realizadas comparações entre o método proposto e outros da literatura, e como pode ser observado na Tabela 2.2, o método proposto alcançou a menor porcentagem de erro de segmentação.

Tabela 2.2: Taxa de erro médio da segmentação depois da remoção de pelos.

Detecção de pelos	Reparação da imagem	Erro de segmentação(%)
Nenhum	Nenhum	16,26
DullRazor	DullRazor	12,11
Toossi et al. (2013)	Método de <i>coherence transport</i>	10,74
Toossi et al. (2013)	Toossi et al. (2013)	9,90

O algoritmo proposto por Bibiloni et al. (2017) foi desenvolvido para imagens de tamanho 600×600 pixels, aproximadamente. Este algoritmo primeiro transforma a imagem para o espaço de cor CIE $L^*a^*b^*$ e a divide por 100. Então o canal L^* , que indica a luminância, é pré-processado para que o contraste da imagem seja aumentado através de uma equalização de histograma. Com isso, para identificar os pelos na imagem, um método de detecção de curvas baseado em operações morfológicas *soft color* é aplicado. Com isso, o método utiliza transformações morfológicas *top hat soft color*, que realça a aparência dos pelos através da variação dos tamanhos e orientações dos elementos estruturantes. Depois da detecção de curvas, é realizado um pós-processamento na máscara de pelos em três passos: primeiro é aplicado um filtro de mediana 9×9 , em seguida é realizada a binarização da máscara e por último as regiões são expandidas em dois pixels. Finalmente, o método de *inpainting*, que também é baseado em morfologia *soft color*, utiliza um filtro de escalas de cinza que substitui os pixels extraídos e mantém os pixels cujos valores já são conhecidos. Segundo Bibiloni et al. (2017), este algoritmo proposto é eficaz na remoção dos pelos, afeta minimamente imagens sem pelos e mantém as características da lesão.

Zaqout (2017) também utilizou uma transformação de espaço de cor antes de remover os pelos. Neste método, a imagem é transformada para o espaço de cor YIQ , o qual o canal Y corresponde à luminância e os canais I (matiz) e Q (saturação) codificam as informações de crominância. Então, é aplicado sob o canal Y da imagem a operação morfológica *bottom hat*, a fim de realizar a detecção dos pelos. Em seguida, é realizada uma cópia do canal Y da imagem resultante do passo anterior, e esta cópia é convertida para binária. Com isso, ambas imagens são divididas em 256 blocos não sobrepostos e, para cada bloco, é calculado o histograma do mesmo, limitando-o em 32 bins. Então, foi considerada a bin com o maior número de ocorrências de pixels. No intervalo contido nesta bin, são calculados os valores que os pixels detectados como pelos receberão, a partir do limite inferior e limite superior do intervalo. Finalmente é aplicada a operação morfológica de fechamento no canal Y da imagem reparada. De acordo com Zaqout (2017), o algoritmo proposto foi avaliado em 200 imagens dermatoscópicas e obteve alta acurácia de detecção e remoção de pelos, como pode ser observado na Tabela 2.3, e pode ser aplicado como um pré-processamento de imagens para a segmentação e classificação de lesões de pele.

Talavera-Martínez et al. (2020) desenvolveram um método de segmentação e remoção de pelos em imagens dermatoscópicas utilizando *deep learning*. O modelo proposto se baseia em

uma arquitetura *encoder-decoder*, utilizando redes neurais convolucionais para a detecção e restauração dos *pixels* dos pelos na imagem dermatoscópica original. Neste trabalho foram utilizadas oito métricas para determinar o desempenho do método proposto e, de acordo com o resultado obtido através destas métricas, [Talavera-Martínez et al. \(2020\)](#) concluíram que seu método é o melhor entre os métodos avaliados em seu trabalho. Alguns dos métodos avaliados no trabalho de [Talavera-Martínez et al. \(2020\)](#), estão presentes nesta revisão de literatura, como o método de [Xie et al. \(2009\)](#) e o método de [Lee et al. \(1997\)](#).

Tabela 2.3: Resultados da detecção e remoção de pelos obtidos pelo algoritmo de [Zaqout \(2017\)](#).

Taxa	Valor (%)
Verdadeiro positivo	97,36
Verdadeiro negativo	95,75
Falso positivo	4,25
Acurácia	95,78

As técnicas aplicadas para solucionar o problema de remoção de pelos variam muito. O uso da morfologia para a detecção dos pelos se mostrou mais presente nos trabalhos revisados ([Lee et al., 1997](#); [Zaqout, 2017](#); [Xie et al., 2009](#); [Bibiloni et al., 2017](#)), mas também foram utilizados detectores de bordas e curvas para realizar a detecção dos pelos. Para a reparação da imagem não houve uma técnica predominante como na detecção, indo de metodologias mais simples, como a substituição pelo vizinho mais próximo ([Lee et al., 1997](#)), até mais complexas como o *coherence transport* ([Toossi et al., 2013](#); [Bornemann e März, 2007](#)). Em trabalhos relacionados a métodos de segmentação ou classificação de lesões de pele baseados em *deep learning*, poucos citam a influência dos pelos em seus resultados. Nos trabalhos que é citado a presença de pelos, é afirmado que a presença dos mesmos influencia minimamente, ou até mesmo não influencia a acurácia de seus resultados ([Youssef et al., 2018](#); [Fornaciali et al., 2016](#)).

A partir desta revisão de literatura, pode ser observado que a utilização de métodos de remoção de pelos como um pré-processamento para a segmentação de lesões de pele pode ser realizada de diversas formas. Com isso, testar novos métodos compostos de técnicas já utilizadas na literatura se mostra interessante, já que estes novos métodos podem obter bons resultados.

Capítulo 3

Fundamentação Teórica

O problema de remoção de pelos pode ser dividido em duas grandes etapas: detectar e remover os pelos na imagem dermatoscópica, e restaurar a mesma sem os pelos. Este capítulo tem como intuito apresentar alguns dos métodos que podem ser utilizados nestas etapas. A suavização em imagens também é abordada, já que muitos métodos de remoção de pelos, propostos na literatura, utilizam a suavização em diferentes circunstâncias. Além disto, também é abordado a segmentação de imagens bem como espaços de cores. Neste capítulo, para exemplificar a aplicação de algumas das técnicas explicadas serão utilizadas imagens de lesões de pele, que foram obtidas da base de dados de [Tschandl et al. \(2018\)](#) e [Codella et al. \(2019\)](#).

3.1 Pré-processamento de imagens

O pré-processamento de imagens consiste em melhorar a imagem de alguma forma, para que os processos seguintes tenham mais chances de sucesso ([Gonzalez e Woods, 2000](#)). Ele pode envolver diversas etapas para diferentes propósitos, como a remoção de ruídos, o realce da imagem e a binarização da imagem ([Acharya e Ray, 2005](#)). Nesta seção serão abordadas técnicas de detecção de bordas, suavização de imagens, operações morfológicas e restauração da imagem.

3.1.1 Detecção de bordas

A detecção de bordas ajuda a extrair diferentes informações de uma imagem, como a separação de duas regiões, por exemplo. De forma geral, a detecção de bordas é realizada através da busca por mudanças súbitas nas intensidades da imagem ([Acharya e Ray, 2005](#)). Nas subseções seguintes são abordados dois detectores de bordas, os operadores de Sobel e de Prewitt.

3.1.1.1 Operador de Sobel

O operador de Sobel (Sobel, 1990) calcula o gradiente de uma vizinhança 3×3 utilizando duas máscaras de convolução (M_1 e M_2):

$$M_1 = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (3.1)$$

$$M_2 = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad (3.2)$$

A convolução da máscara M_1 gera uma componente de gradiente G_x na orientação horizontal, enquanto M_2 gera uma G_y na vertical. A magnitude, G , e a direção, θ , do gradiente podem ser calculadas de acordo com as Equações 3.3 e 3.4, respectivamente (Acharya e Ray, 2005):

$$G[A(x, y)] = \sqrt{G_x^2 + G_y^2}, \text{ e} \quad (3.3)$$

$$\theta(x, y) = \tan^{-1}(G_x/G_y), \quad (3.4)$$

onde A é a imagem, e (x, y) são as coordenadas do *pixel* avaliado. Como pode ser observado na Figura 3.1, a máscara gerada por este operador contém regiões em branco que correspondem a alguns dos pelos na imagem original.



Figura 3.1: Resultado da aplicação do operador de Sobel: (a) Imagem original (1024×768), (b) imagem binária com as bordas detectadas em branco.

3.1.1.2 Operador de Prewitt

De forma análoga ao operador de Sobel, o operador de Prewitt (Acharya e Ray, 2005) também pode ser usado para calcular a magnitude da borda detectada, assim como sua ori-

entação. Este operador utiliza oito máscaras 3×3 para realizar a convolução com a imagem original e detectar as bordas contidas na mesma. Duas das máscaras utilizadas por este filtro são da seguinte forma:

$$H = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \quad (3.5)$$

$$V = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} \quad (3.6)$$

onde H detecta bordas horizontais e V bordas verticais. As outras 6 máscaras podem ser geradas a partir de rotações sucessivas de 90° das máscaras 3.5 ou 3.6 (Acharya e Ray, 2005). Para a detecção das bordas, este operador calcula o gradiente de cada *pixel* na imagem em ambas direções através da convolução com suas máscaras e seleciona o maior valor. Então, este valor selecionado é usado como a intensidade do *pixel* na imagem resultante, que contém apenas as bordas detectadas (Yang et al., 2011). Como pode ser visto na Figura 3.2, aplicação deste detector de bordas em uma imagem dermatoscópica gera um resultado similar ao operador de Sobel (Figura 3.1).



Figura 3.2: Resultado da aplicação do filtro de Prewitt: (a) Imagem original (1024×768) e (b) imagem binária com as bordas detectadas em branco.

3.1.2 Operações morfológicas

A morfologia matemática, que pode ser utilizada em aplicações de processamento de imagens (Lee et al., 1997; Kiani e Sharafat, 2011), é baseada na teoria de conjuntos, então, como regiões de uma imagem podem ser tratadas como conjuntos de forma que *pixels* em uma mesma região pertençam ao mesmo conjunto. Ela pode ser considerada uma ferramenta para a extração de componentes de uma imagem que podem ser úteis para a representação e descri-

ção da forma de uma região da imagem (Gonzalez e Woods, 2000). Nas próximas subseções são abordados alguns operadores morfológicos, como os de erosão, dilatação, abertura, fechamento e *top-hat*.

3.1.2.1 Operação de dilatação

A operação morfológica de dilatação tem a característica de expandir as regiões onde ela é aplicada. Sejam A e B dois conjuntos e \emptyset o conjunto vazio. A dilatação de A por B , $A \oplus B$, pode ser definida como:

$$A \oplus B = \{x | (\hat{B})_x \cap A \neq \emptyset\}, \quad (3.7)$$

onde x são os elementos do conjunto resultante da operação e a reflexão de B , \hat{B} , é definida por:

$$\hat{B} = \{x | x = -b, \text{ para } b \in B\}. \quad (3.8)$$

O conjunto B é denominado elemento estruturante da dilatação. Com isso, pode-se dizer que o resultado da dilatação de A pelo elemento estruturante B é o conjunto de todos deslocamentos x tais que \hat{B} e A sobreponham-se em pelo menos um elemento não nulo (Gonzalez e Woods, 2000). O efeito de expansão das regiões que este operador provoca pode ser observado na Figura 3.3, onde foi utilizado o elemento estruturante quadrado de tamanho 3×3 , composto de apenas números 1.




Figura 3.3: Resultado da aplicação da dilatação em uma imagem binária (1024×768): (a) Imagem após a aplicação do operador Sobel demonstrada na Figura 3.1 e (b) imagem após a dilatação.

3.1.2.2 Operação de erosão

De forma contrária ao operador de dilatação, o operador de erosão tem a característica de reduzir regiões onde o mesmo é aplicado. Sejam A e B dois conjuntos, onde a erosão de A

por B , $A \ominus B$, pode ser definida como:

$$A \ominus B = \{x | (B)_x \subseteq A\}, \quad (3.9)$$

ou seja, a erosão da imagem A pelo elemento estruturante B é o conjunto de todos elementos x tais que B , quando transladado por x , fique contido em A (Gonzalez e Woods, 2000). O efeito de redução das regiões pode ser observado na Figura 3.4, onde foi utilizado o elemento estruturante quadrado de tamanho 3×3 , composto de apenas valores iguais a 1.




Figura 3.4: Resultado da aplicação da erosão em uma imagem binária (1024×768): (a) Imagem após a operação de dilatação demonstrada na Figura 3.3 e (b) imagem após a erosão.

3.1.2.3 Operação de fechamento

A operação de fechamento pode ser utilizada, por exemplo, para preencher buracos em regiões ou unir regiões muito próximas que estão desconexas (Gonzalez e Woods, 2000). Esta operação é a aplicação de uma dilatação seguida de uma erosão. Seja A um conjunto e B um elemento estruturante. O fechamento de A por B , $A \bullet B$, é definido como:

$$A \bullet B = (A \oplus B) \ominus B. \quad (3.10)$$

Como pode ser observado na Figura 3.5, onde a operação de fechamento foi aplicada com elemento estruturante quadrado de tamanho 3×3 e composto de apenas valores iguais a 1, algumas regiões que estava desconexas foram conectadas e preenchidas.

3.1.2.4 Operação de abertura

Quando aplicada sobre uma região, a operação de abertura pode, por exemplo, suavizar a bordas (Gonzalez e Woods, 2000). Diferentemente da operação de fechamento, a operação de abertura é composta de uma operação de erosão seguida de uma operação de dilatação. Seja




Figura 3.5: Resultado da aplicação da operação de fechamento em uma imagem binária (1024×768): (a) Imagem após a aplicação do operador Sobel demonstrada na Figura 3.1 e (b) imagem após a operação de fechamento.

A um conjunto e B um elemento estruturante, a abertura de A por B , $A \circ B$, é definida como:

$$A \circ B = (A \ominus B) \oplus B. \quad (3.11)$$

Pode ser observado na Figura 3.6, onde a operação de abertura foi aplicada com elemento estruturante quadrado de tamanho 3×3 e composto de apenas valores iguais a 1, algumas regiões foram eliminadas devido a erosão e as restantes sofreram pequenas alterações.




Figura 3.6: Resultado da aplicação da operação de abertura em uma imagem binária (1024×768): (a) Imagem após a operação de dilatação demonstrada na Figura 3.3 (b) imagem após a operação de abertura.

3.1.2.5 Operação morfológica *top-hat*

O operador morfológico *top-hat* pode ser aplicado de duas formas (Maragos, 2005):

- **Fechamento:** é a diferença entre a imagem original e a operação morfológica de fechamento dela com um elemento estruturante.
- **Abertura:** é a diferença entre a imagem original e a operação morfológica de abertura dela com um elemento estruturante.

Em sua forma de abertura, o operador realça elementos mais claros na imagem, e na de fechamento realça estruturas mais escuras. Como pode ser visualizado na Figura 3.7, a aplicação do operador *top-hat* de fechamento resultou em uma imagem com as estruturas mais escuras da imagem original, neste caso os pelos.



Figura 3.7: Resultado da aplicação da operação *top-hat* de fechamento: (a) Imagem original (1024×768) e (b) imagem binária resultante da operação.

3.1.3 Restauração de imagem

A restauração é aplicada em imagens que foram degradadas de alguma maneira, na tentativa de reconstruí-las para seu estado original (Gonzalez e Woods, 2000). Nesta seção, uma técnica de restauração de imagens será apresentada: a substituição pelo vizinho mais próximo.

3.1.3.1 Substituição pelo vizinho mais próximo

Na técnica de substituição pelo vizinho mais próximo (Lee et al., 1997), dada uma região a ser restaurada, os valores dos *pixels* da região são substituídos pelos valores dos *pixels* mais próximos que não estão contidos na mesma.

Seja $I(x, y)$ a intensidade do *pixel* de coordenadas (x, y) a ser substituído, e $I_1(x_1, y_1)$ e $I_2(x_2, y_2)$ as intensidades dos dois *pixels* de coordenadas (x_1, y_1) e (x_2, y_2) , respectivamente, mais próximos ao ser substituído. Para selecionar I_1 e I_2 , Lee et al. (1997) calculou 8 segmentos de reta a partir dos *pixels* da região. Com isso, a partir do menor segmento de reta contido na região, são selecionados dois *pixels* localizados em extremidades opostas do segmento de reta

e a 11 *pixels* de distância da borda da região. O novo valor do *pixel*, $I_n(x, y)$, é definido como:

$$I_n(x, y) = I_2(x_2, y_2) * \frac{D(I(x, y), I_1(x_1, y_1))}{D(I_1(x_1, y_1), I_2(x_2, y_2))} + I_1(x_1, y_1) * \frac{D(I(x, y), I_2(x_2, y_2))}{D(I_1(x_1, y_1), I_2(x_2, y_2))}, \quad (3.12)$$

onde:

$$D(A(a, b), B(c, d)) = \sqrt{(c - a)^2 + (d - b)^2}, \quad (3.13)$$

sendo D a distância entre dois *pixels*, A e B , de coordenadas (a, b) e (c, d) , respectivamente.

3.1.4 Suavização de imagem

A suavização de imagens pode ser realizada para a redução de ruídos, correção de descon- tinuidades em linhas ou curvas e efeitos de borramento para remoção de pequenos detalhes (Gonzalez e Woods, 2000). Nas subseções a seguir são apresentados dois filtros utilizados para suavização de imagens, o filtro da média e o da mediana, que foram utilizados em alguns tra- balhos da literatura como o de Lee et al. (1997) e de Kiani e Sharafat (2011). Estes filtros não se demonstraram necessários no presente trabalho pois a suavização realizada pelos mesmos não é significativa o suficiente ao ponto de melhorar os resultados.

3.1.4.1 Filtro da média

O filtro da média é uma técnica de suavização utilizada para reduzir ruídos em imagens. Esta técnica substitui um *pixel* de uma imagem pelo valor da média deste *pixel* com seus vizinhos, que são determinados por uma máscara (Gonzalez e Woods, 2000). Uma máscara 3×3 utilizada para o filtro de média, por exemplo, tem a seguinte forma:

$$M = \frac{1}{9} * \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (3.14)$$

Quanto maior a dimensão desta máscara, mais perceptível é o efeito de borramento provo- cado pelo filtro na imagem. Este efeito pode ser observado na Figura 3.8. Existem variações deste filtro, como por exemplo adicionar pesos na máscara de forma que vizinhos mais próxi- mos tenham mais influência no valor final do *pixel* avaliado.

3.1.4.2 Filtro da mediana

O filtro de mediana é um método de suavização não linear, que utiliza uma janela para calcular a mediana dos valores da imagem que estão contidos nesta janela. O filtro consiste em substituir o valor do *pixel* central avaliado pelo valor desta mediana. Como o tamanho desta janela influencia na imagem resultante pode ser observado na Figura 3.9. Diferentemente do




Figura 3.8: Influência do tamanho da máscara do filtro de média: (a) Imagem original (1024×768), (b) máscara 10×10 e (c) máscara 20×20 .

filtro de média, abordado anteriormente, este filtro realiza a suavização da imagem sem que as bordas e estruturas finas na imagem fiquem com o aspecto de borrado (Oliveira et al., 2016).




Figura 3.9: Resultado da influência do tamanho da janela do filtro da mediana: (a) Imagem original (1024×768), (b) janela 10×10 e (c) janela 20×20 .

3.2 Segmentação de imagem

A tarefa de segmentação é dividir uma imagem em diferentes regiões, de modo que os *pixels* que pertençam a cada uma destas regiões não se sobreponham e tenham propriedades similares (Acharya e Ray, 2005). Se a divisão da imagem for em apenas duas regiões, comumente se obtém uma máscara binária como resultado de uma segmentação, onde *pixels* com valor 1 (branco) representam uma das regiões e de valor 0 (preto) a outra. Se mais de duas regiões forem identificadas, os *pixels* pertencentes a cada uma delas recebe um valor diferente. Nesta seção serão abordados diferentes métodos de segmentação de imagens, e destes métodos, o selecionado para o presente trabalho foi o método de segmentação de Chan-Vese, que é baseado em crescimento de regiões, pois o mesmo se mostrou mais adequado para o problema.

3.2.1 Limiarização

Métodos de segmentação baseados em limiarização são baratos computacionalmente (Acharya e Ray, 2005). Estes métodos consistem na definição de limiares ótimos, que são utilizados para particionar a imagem em diferentes regiões. Proposto por Otsu (1979), o método de segmentação de Otsu é baseado em limiarização e divide imagens em duas regiões, *foreground* e *background*. Para realizar esta divisão, ele busca iterativamente por um valor limiar que maximize a variância, σ_b^2 , entre as regiões. Este valor é obtido a partir da seguinte equação:

$$\sigma_b^2 = \omega_0(\mu_0 - \mu_T)^2 + \omega_1(\mu_1 - \mu_T)^2, \quad (3.15)$$

onde ω_0 e ω_1 são as probabilidades das regiões separadas pelo limiar l . Estas probabilidades são obtidas a partir das N bins do histograma da imagem:

$$\omega_0 = \sum_{i=0}^{l-1} p(i), e \quad (3.16)$$

$$\omega_1 = \sum_{i=l}^{N-1} p(i), \quad (3.17)$$

e as médias da intensidades das regiões, μ_0 e μ_1 , e a média de todas intensidades das imagem, μ_T são obtidas a partir de:

$$\mu_0 = \sum_{i=0}^{l-1} \frac{ip(i)}{\omega_0}, \quad (3.18)$$

$$\mu_1 = \sum_{i=l}^{N-1} \frac{ip(i)}{\omega_1}, e \quad (3.19)$$

$$\mu_T = \sum_{i=l+1}^l ip(i). \quad (3.20)$$

Como pode ser observado na Figura 3.10, o método de segmentação de Otsu dividiu a imagem original da lesão em duas regiões, e atribuiu o valor 1 (branco) para a região da lesão e 0 (preto) para a região da pele.

3.2.2 Crescimento de regiões

Nesta técnica de segmentação é realizado o agrupamento de *pixels* em regiões a partir de um conjunto de *pixels* iniciais, denominados sementes. As regiões são expandidas a partir das sementes, de modo que apenas *pixels* com características similares às sementes serão incluídos na mesma região em que elas se encontram. Algumas das características utilizadas para o agrupamento de *pixels* são: o nível de cinza, a cor, a textura ou a estatística da população




Figura 3.10: Aplicação do método de segmentação de Otsu: (a) Imagem original (1022×767), (b) região segmentada pelo método de Otsu.

de *pixels*. O crescimento das regiões é realizado iterativamente, de modo que o resultado final sejam regiões com fronteiras definidas por polígonos fechados (Acharya e Ray, 2005).

A segmentação de imagens baseada no crescimento de regiões pode ser formulada como a partição de uma imagem I em n regiões, R_1, R_2, \dots, R_n , tais que:

1. $\bigcup_{i=1}^n R_i = I$;
2. R_i é uma região conexa, $i = 1, 2, \dots, n$;
3. $R_i \cap R_j = \emptyset$, $\forall i, j$, tal que $i \neq j$;
4. $P(R_i) = \text{Verdadeiro}$ para $i = 1, 2, \dots, n$;
5. $P(R_i \cup R_j) = \text{Falso}$ para $i \neq j$;

onde \emptyset é o conjunto vazio e $P(R_i)$ é um predicado lógico sobre a região R_i .

O item 1 indica que todos os *pixels* da imagem deve fazer parte de uma região. Já o item 2 especifica que as regiões devem ser conexas. O item 3 mostra que um *pixel* deve fazer parte de apenas uma região. O item 4 indica que os *pixels* de uma região devem satisfazer uma mesma propriedade e o item 5 especifica que *pixels* de regiões diferentes não devem satisfazer a mesma propriedade (Gonzalez e Woods, 2000).

O resultado de uma segmentação utilizando o método de contorno ativo sem bordas de Chan e Vese (2001), que é baseado em crescimento de regiões, pode ser observado na Figura 3.11. Modelos baseados em contorno ativo evoluem uma curva inicial de acordo com restrições impostas no modelo de forma que esta curva detecte diferentes regiões na imagem (Chan e Vese, 2001).




Figura 3.11: Aplicação de um método de segmentação baseado em crescimento de regiões: (a) Imagem original (1022×767), (b) região segmentada pelo método de contorno ativo sem bordas.

3.3 Espaço de cores

Os espaços de cores são maneiras de especificar cores. A cor é a forma que o sistema visual humano interpreta o espectro eletromagnético, aproximadamente entre 300 e 830 nm (Tkalcic e Tasic, 2003). Nesta seção serão apresentados dois espaços de cores: o RGB e o YIQ.

3.3.1 Espaço de cores RGB

O espaço de cores RGB é descrito por três componentes primitivas, R, G e B, que correspondem respectivamente às cores vermelho, verde e azul. Estas três componentes são combinadas a fim de reproduzir um espectro cromático, que pode ser representado através de um cubo de valores, normalizados entre zero e um, onde estes valores representam as intensidades de cada uma das componentes primitivas. Neste cubo, representado na Figura 3.12, a origem, $(0, 0, 0)$, representa a cor preta e o ponto de valores $(1, 1, 1)$ representa a cor branca (Ibraheem et al., 2012).

3.3.2 Espaço de cores YIQ

O espaço de cores YIQ é utilizado pelo sistema de televisão NTSC dos Estados Unidos. Neste espaço de cores, a componente Y representa a luminância, e as componentes I e Q as informações de cromaticidade. Os valores das componentes deste espaço de cores podem ser obtidos através dos valores das componentes do espaço de cores RGB, abordado na Subseção 3.3.1, a partir das Equações 3.21, 3.22 e 3.23 (Tkalcic e Tasic, 2003).

$$Y = 0.299R + 0.587G + 0.114B \quad (3.21)$$

$$I = 0.596R - 0.274G - 0.322B \quad (3.22)$$

$$Q = 0.211R - 0.523G + 0.312B \quad (3.23)$$




Figura 3.12: Espaço de cores **RGB** representado na forma de um cubo (Cunha, A. L., 2016).

3.4 Métricas de avaliação

Para avaliar a eficácia de algoritmos de pré-processamento e segmentação, diferentes métricas podem ser utilizadas. Estas métricas geralmente são baseadas nos seguintes valores:

- **Verdadeiro Positivo (VP)**: quando um *pixel* foi identificado como parte da **ROI** tanto na imagem processada, quanto no *ground-truth*.
- **Verdadeiro Negativo (VN)**: quando um *pixel* não foi identificado como parte da **ROI** tanto na imagem processada, quanto no *ground-truth*.
- **Falso Positivo (FP)**: quando um *pixel* foi identificado como parte da **ROI** na imagem processada, mas não faz parte da região no *ground-truth*.
- **Falso Negativo (FN)**: quando um *pixel* não foi identificado como parte da **ROI** na imagem processada, mas faz parte da região no *ground-truth*.

Cada um destes valores são obtidos através da contagem de seus *pixels* correspondentes, que são resultantes da comparação da região obtida na segmentação de uma imagem com o *ground-truth* da base de dados. Nesta seção, são abordadas as métricas de acurácia, sensibilidade, especificidade, coeficiente de Dice e índice de similaridade de Jaccard.

A métrica de acurácia (**ACC**) aplicada em segmentação de imagens é utilizada para quantificar o quão correta foi a segmentação realizada em relação ao *ground-truth*. Se o número de falsos positivos e negativos for 0, a acurácia da segmentação é de 100%. A acurácia pode ser

calculada a partir da seguinte fórmula (Fawcett, 2004):

$$ACC = \frac{VP + VN}{VP + VN + FP + FN}. \quad (3.24)$$

A métrica de sensibilidade (SE), ou taxa de detecção de verdadeiros positivos, é o número de *pixels* que foram identificados corretamente como parte da ROI. Ela é calculada da seguinte maneira (Fawcett, 2004):

$$SE = \frac{VP}{VP + FN}. \quad (3.25)$$

A métrica de especificidade (SP), ou taxa de verdadeiros negativos, é o número de *pixels* que foram identificados corretamente como não fazendo parte da região da ROI. Ela é calculada a partir da seguinte fórmula (Fawcett, 2004):

$$SP = \frac{VN}{VN + FP}. \quad (3.26)$$

O coeficiente de Dice (Dice, 1945), quando aplicado na segmentação de imagens, é utilizado para quantificar a similaridade da imagem segmentada com o *ground-truth*. O coeficiente de Dice (DSC), é dado por:

$$DSC = \frac{2VP}{2VP + FP + FN}. \quad (3.27)$$

O índice de similaridade de Jaccard é um valor que indica a similaridade de dois conjuntos através do número de elementos contidos na interseção deles, dividido pelo número de elementos contidos na união dos mesmos (Metcalf e Casey, 2016). Formalmente, o índice de similaridade de Jaccard (J), é obtido através de:

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|}, \quad (3.28)$$

onde A e B são conjuntos finitos.

As métricas descritas nesta seção, quando aplicadas na avaliação de algum método de segmentação, podem trazer diversas informações sobre o mesmo. A métrica de sensibilidade indica a capacidade do método de segmentação de identificar corretamente os *pixels* que fazem parte da ROI. Já a de especificidade, mostra a capacidade do método de identificar *pixels* que não fazem parte da ROI. A métrica de acurácia mostra o quão precisa foi a segmentação e as métricas de similaridade, índice de Jaccard e coeficiente de Dice, indicam o quão similar é a região segmentada do seu *ground-truth*.

Capítulo 4

Metodologia

O presente projeto tem como objetivo comparar diferentes técnicas de remoção de pelos aplicadas em imagens dermatoscópicas, para analisar a influência de tais técnicas no processo de segmentação de imagens e quais são as melhores técnicas de remoção de pelos. A metodologia proposta é dividida em três fases: (1) a remoção dos pelos da imagem original, (2) a segmentação da lesão após a remoção dos pelos, e (3) a avaliação do método, a partir da análise das métricas obtidas por meio da comparação do resultado da segmentação com o seu *ground-truth*. O fluxograma da metodologia proposta pode ser visualizado na Figura [4.1](#). Neste capítulo, serão definidas as técnicas de remoção de pelos foram comparadas, assim como o método de segmentação da lesão e os processos de avaliação utilizados neste trabalho.

4.1 Remoção de pelos

Para efetuar a remoção dos pelos, o primeiro passo foi realizar a detecção dos pelos na imagem. Como a imagem binária resultante da detecção dos pelos geralmente contém estruturas muito finas, mostrou-se necessário realizar outro passo para aprimorar estas imagens, com o intuito de aumentar o tamanho destas estruturas. No último passo, as regiões identificadas como pelos são restauradas na imagem original. Com isso, foi obtido como resultado a imagem da lesão com os pelos removidos que será segmentada na fase seguinte. Nas subseções a seguir são abordadas quais técnicas de cada um destes passos serão comparadas no presente trabalho.

4.1.1 Detecção de pelos

Para a detecção dos pelos, diferentes técnicas podem ser utilizadas, tais como operações morfológicas e detectores de bordas. A detecção de pelos utilizando detectores de borda geralmente é mais complexa do que a com operadores morfológicos por envolver alguns passos extras, tais como a realização de transformadas ([Kiani e Sharafat, 2011](#)) e a aplicação de filtros

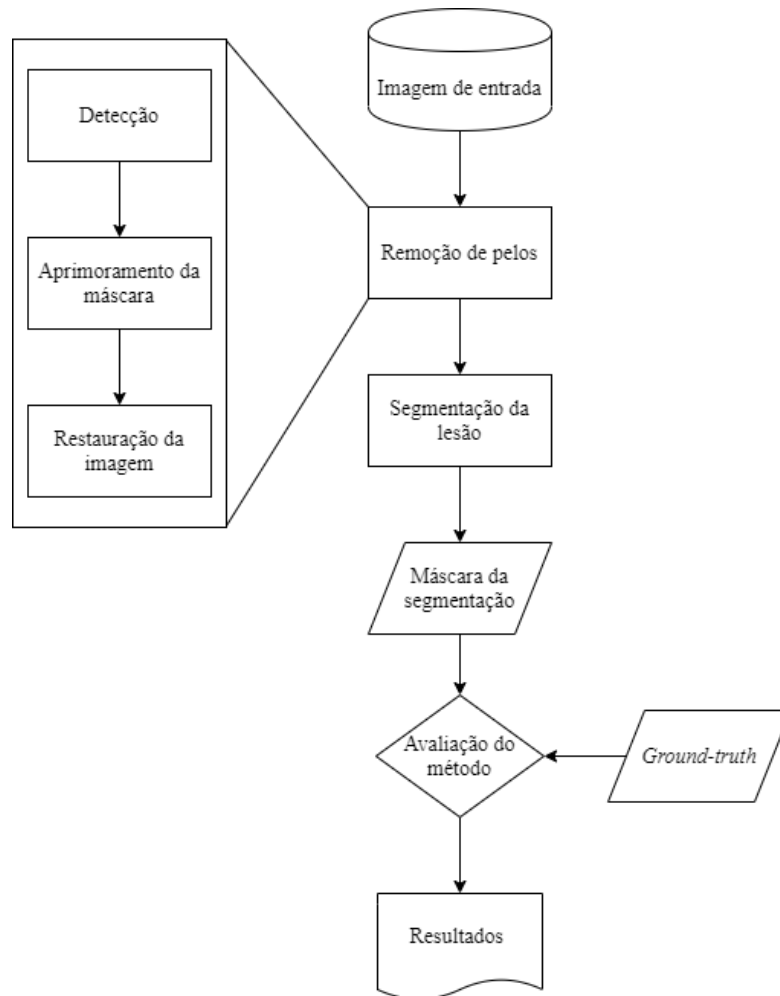


Figura 4.1: Fluxograma da metodologia proposta.

e operações morfológicas (Toossi et al., 2013). Portanto, neste trabalho foram comparados três métodos baseados em operações morfológicas para a detecção de pelos:

1. Operação morfológica generalizada de fechamento (Lee et al., 1997);
2. Operação morfológica *bottom-hat* (Maragos, 2005) aplicada sobre o canal Y de uma imagem no espaço de cores *YIQ* e
3. Operação morfológica *bottom-hat* (Maragos, 2005) em uma imagem RGB.

O método 1 foi considerado para avaliação uma vez que é utilizado como base de comparação em vários outros trabalhos (Xie et al., 2009; Zhou et al., 2008; Toossi et al., 2013). Os métodos 2 e 3 foram considerados com o objetivo de verificar se a mudança do espaço de cores de uma imagem RGB para o *YIQ* melhora a detecção dos pelos. Segundo Zaqout (2017), os pelos são mais bem representados por uma imagem de apenas luminância, e por este motivo a

operação *bottom-hat* é aplicada sobre o canal Y , que representa a componente de luminância da imagem.

4.1.2 Aprimoramento das máscaras

As máscaras obtidas através do passo de detecção de pelos, apresentado na subseção anterior, são compostas de regiões longas e finas. Após vários experimentos preliminares do presente trabalho foi identificado que se as máscaras utilizadas no passo de restauração de imagem forem compostas de estruturas muito longas e finas, o resultado dos métodos de restauração aplicados não é promissor. Logo a aplicação da operação morfológica de dilatação, citada na Subseção 3.1.2.1 do capítulo anterior, irá fazer com que as regiões nas máscaras sejam expandidas, assim podendo melhorar a eficácia dos métodos de restauração.

4.1.3 Restauração da imagem

Após o aprimoramento da máscara, foi realizada a restauração da imagem. Neste passo, é necessário um método que não introduza muitos ruídos, já que o propósito da remoção de pelos é removê-los. Foi realizada a comparação dos seguintes métodos de reparação de imagens:

1. *Inpainting* baseado em exemplos (Criminisi et al., 2004);
2. Substituição pelo vizinho mais próximo (Lee et al., 1997).

O método 1, foi utilizado por depender de uma boa máscara de segmentação das regiões a serem reparadas. Assim será possível verificar se os pelos foram segmentados apropriadamente, já que a segmentação correta dos mesmos pode fazer com que esse método de *inpainting* produza um resultado melhor. Finalmente, o método 2 foi considerado no presente trabalho, pois como mencionado anteriormente, também foi utilizado como base de comparação de diversos outros estudos na literatura.

4.2 Segmentação da lesão

A partir da imagem resultante da fase de remoção de pelos, é realizada a segmentação da lesão na imagem. A escolha de um método de segmentação de qualidade é muito importante, já que os métodos de remoção de pelos serão avaliados a partir do resultado da segmentação da lesão na imagem com os pelos removidos. Portanto, no presente trabalho foi utilizado o modelo de contorno ativo sem bordas para segmentação de imagens proposto por Chan e Vese (2001). Este modelo foi utilizado no presente trabalho pois ele apresenta algumas vantagens sobre outros modelos baseados em contorno ativo, segundo Oliveira et al. (2016). O modelo proposto por Chan e Vese (2001) tem vantagens sobre outros modelos de contorno ativo, como um melhor comportamento quando aplicado em imagens contendo algumas particularidades

tais como: grande variações nas intensidades da imagem, limites mal definidos das regiões e limites de regiões que são difíceis de serem definidos através do gradiente.

O algoritmo de segmentação de Chan-Vese utilizado neste trabalho foi implementado utilizando o *software* MATLAB R2009a e está disponibilizado para *download* em um site^[1]. Nesta implementação o algoritmo recebe como entrada cinco parâmetros. Três destes parâmetros definem o comportamento do algoritmo, que são: o tipo de máscara que será utilizada para gerar as curvas que serão expandidas, o número de iterações do algoritmo e o peso do termo de comprimento. Os outros dois parâmetros são a imagem a ser segmentada e o método do algoritmo a ser utilizado, neste caso o Chan-Vese tradicional.

¹<https://sites.google.com/site/rexstribeofimageprocessing/chan-vese-active-contours/matlabcodesforactivecontours>. Acessado em 7 de fevereiro de 2021.

Capítulo 5

Experimentos Computacionais

Neste capítulo será apresentada a base de imagens utilizada e os resultados dos experimentos realizados para cada um dos métodos de remoção de pelos analisados no presente trabalho. Os experimentos foram conduzidos considerando os seguintes passos: 1) foi aplicado o método de remoção de pelos a ser avaliado nas imagens dermatoscópicas originais, 2) foi realizada a segmentação da lesão na imagem resultante do primeiro passo e 3) as métricas de sensibilidade, especificidade, acurácia, índice de similaridade de Jaccard e coeficiente de Dice foram calculadas a partir da imagem com a região da lesão segmentada. De acordo com os resultados das métricas de avaliação, foi realizada a análise de cada um dos métodos de remoção de pelos.

5.1 Base de imagens

A base de imagens considerada neste trabalho foi usada na tarefa de segmentação de lesões da competição [ISIC 2018: Skin Lesion Analysis Towards Melanoma Detection](#) ([Codella et al., 2019](#); [Tschandl et al., 2018](#)). O [ISIC](#) é uma colaboração internacional que tem como objetivo melhorar o diagnóstico de câncer melanoma. A base de imagens contém 2.594 imagens dermatoscópicas de lesões de pele, com resoluções entre 771×750 e 6748×4499 *pixels*. Algumas das imagens da base podem ser visualizadas na Figura [5.1](#). Cada imagem [RGB](#) original desta base contém seu *ground-truth* (imagem binária) correspondente, que identifica a região da lesão estabelecida por especialistas. Também foram disponibilizadas 100 imagens para validação, 1000 imagens para teste, mas os *ground-truths* das imagens de validação e teste não são fornecidos, logo não foram utilizadas no presente trabalho.

Para realizar os experimentos do presente trabalho foram consideradas 300 imagens da base de imagens citada anteriormente, considerando uma variedade nas amostras para facilitar o processamento. Estas 300 imagens foram divididas em dois conjuntos de 150 imagens, onde um dos conjuntos é composto de imagens que contém pelos, enquanto o outro é composto de imagens que não contém pelos. As imagens foram separadas nesses dois conjuntos a fim de




Figura 5.1: Quatro exemplos de imagens dermatoscópicas da base de dados do ISIC 2018: (a) e (b) imagens com pelos, e (c) e (d) imagens sem pelos (Codella et al., 2018).

verificar se a remoção de pelos é eficaz nas imagens com pelo e para verificar o quão alteradas são as imagens sem pelos.

5.2 Experimentos realizados

Os experimentos realizados no presente trabalho consistiram de realizar a segmentação da lesão contida nas imagens da base de entrada após aplicar diferentes métodos de remoção de pelos nestas imagens. Foram utilizados dois métodos de reparação de imagens: a substituição pelo vizinho mais próximo e o *inpainting* baseado em exemplos. Para cada um destes métodos, foram realizados experimentos com três métodos de detecção de pelos: o *bottom hat* RGB, o *bottom hat Y Channel* e a operação generalizada de fechamento. Estes métodos de detecção de pelos geram a máscara binária que é utilizada para guiar os métodos de *inpainting*.

Cada um dos métodos foram avaliados após a remoção dos pelos e da segmentação da lesão contida na imagem original. Com a imagem binária resultante do passo de segmentação, foi calculado a matriz de confusão através da comparação dela com seu *ground-truth* correspondente da base de imagens. A partir desta matriz foi realizado o cálculo das métricas de avaliação para cada um dos métodos de remoção de pelos. As métricas utilizadas foram a acurácia, sensibilidade, especificidade, coeficiente de Dice e o índice de similaridade de Jaccard, todas descritas no Capítulo 3. Com os resultados destas métricas, foi possível avaliar e

comparar os métodos compostos das técnicas descritas na Seção [4.1](#)

Também foram realizados experimentos com o aprimoramento das máscaras binárias geradas pelos métodos de detecção de pelos. Para determinar o tamanho do elemento estruturante a ser utilizado no aprimoramento através da operação morfológica da dilatação das máscaras de detecção de pelos, elementos estruturantes de diferentes tamanhos foram analisados de maneira visual para determinar o elemento a ser utilizado no aprimoramento. Os elementos estruturantes testados foram elementos quadrados, pois abrangem uma área maior que os demais formatos, de dimensões ímpares, variando de 3×3 até 11×11 . Foi selecionado para ser utilizado no presente trabalho um elemento estruturante quadrado de dimensões 5×5 para a aplicação da operação de dilatação, uma vez que apresentou melhores resultados para o passo de aprimoramento das máscaras. Os elementos estruturantes com menores dimensões não foram selecionados pois a alteração na máscara quando aplicados era insignificante, ou seja, os mesmos não deformaram a região suficientemente. Já os elementos estruturantes com maiores dimensões provocaram alterações significantes nas regiões, assim causando deformações que afetaram drasticamente o formato original da região.

Como mencionado anteriormente na Subseção [4.2](#), o algoritmo de segmentação utilizado neste trabalho requer a definição de três parâmetros. Os parâmetros utilizados neste trabalho foram definidos empiricamente de forma que o número de iterações escolhido foi 200, o peso do termo de comprimento escolhido foi 0, 2, e o tipo da máscara selecionada foi uma composta de várias circunferências que serão expandidas ao longo das iterações do algoritmo.

5.3 Resultados

Nesta seção serão apresentados os resultados dos experimentos realizados no presente trabalho. Estes experimentos foram realizados em uma máquina com 8 GB de RAM, processador intel core i7 8^a geração com 8 núcleos e placa de vídeo Nvidia MX150 com 2 GB de memória dedicada.

5.3.1 Segmentação da lesão sem remoção de pelos

Primeiramente, foi realizado o experimento da segmentação da lesão das imagens sem a aplicação de um método de remoção de pelos. Este experimento foi realizado para que os resultados do mesmo possam ser comparados com os resultados obtidos nos experimentos realizados com métodos de remoção de pelos, e assim verificar se a remoção de pelos realmente melhora a precisão da segmentação da lesão.

Como pode ser observado na Tabela [5.1](#), a segmentação em imagens sem pelos obteve um resultado melhor em todas as métricas de avaliação. Esse resultado pode sugerir que a remoção de pelos ajuda a segmentação da lesão a produzir um resultado melhor, já que no conjunto de imagens sem pelos a segmentação da lesão foi mais eficaz.

Tabela 5.1: Resultados das métricas de avaliação para a segmentação da lesão sem a remoção de pelos.

	Métricas de Avaliação				
	ACC	SE	SP	J	DSC
Imagens com pelos	0.827995	0.739843	0.881160	0.547274	0.674313
Imagens sem pelos	0.873612	0.792712	0.936810	0.676124	0.780543

5.3.2 Segmentação da lesão com remoção de pelos: substituição pelo vizinho mais próximo

O método de *inpainting* por substituição pelo vizinho mais próximo apresentou resultados promissores nos métodos onde houve o aprimoramento das máscaras de detecção de pelos, diferentemente dos métodos onde não foi realizado o aprimoramento. Tendo os resultados da Tabela 5.1 como base de comparação, a aplicação da remoção de pelos utilizando este método de *inpainting* apresentou uma melhora pequena comparado aos resultados da segmentação de lesão sem a remoção de pelos. O resultado da aplicação deste método pode ser observado na Figura 5.2.

Como pode ser observado na Tabela 5.2, os diferentes métodos de detecção de pelos apresentaram apenas pequenas variações nos resultados das métricas de avaliação, tanto no conjunto de imagens com pelos quanto no conjunto de imagens sem pelos. Isto indica que para o método de *inpainting* por substituição pelo vizinho mais próximo os diferentes métodos de detecção de pelos não influenciaram significativamente nos resultados da segmentação da lesão. Apesar de pouca melhora, pode-se observar que o método operação generalizada de fechamento se destacou por ter o melhor resultado em quase todas as métricas de avaliação, em ambos conjuntos de imagens.



Figura 5.2: Aplicação do método de remoção de pelos utilizando a substituição pelo vizinho mais próximo: (a) Imagem original, (b) imagem após a remoção dos pelos.

Já com o aprimoramento da máscara de detecção dos pelos, os resultados das métricas

Tabela 5.2: Resultados das métricas de avaliação para a segmentação da lesão com *inpainting* por substituição pelo vizinho mais próximo.

		Métricas de Avaliação					
Aprimoramento		Detecção dos pelos	ACC	SE	SP	J	DSC
Imagens com pelos	Não	Bottom Hat Y Channel	0.83576	0.72035	0.89496	0.55237	0.67815
		Bottom Hat RGB	0.83592	0.72055	0.89502	0.55256	0.67827
		Op. generalizada de fechamento	0.84097	0.72063	0.90092	0.55672	0.68199
	Sim	Bottom Hat Y Channel	0.83785	0.89773	0.72691	0.55868	0.68512
		Bottom Hat RGB	0.84189	0.72052	0.90226	0.55848	0.68448
		Op. generalizada de fechamento	0.83790	0.72767	0.89885	0.55964	0.68536
Imagens sem pelos	Não	Bottom Hat Y Channel	0.86873	0.80249	0.92481	0.67302	0.77813
		Bottom Hat RGB	0.87210	0.80515	0.93083	0.67310	0.77809
		Op. generalizada de fechamento	0.87538	0.80317	0.93553	0.67843	0.78212
	Sim	Bottom Hat Y Channel	0.87201	0.80813	0.92806	0.67504	0.78039
		Bottom Hat RGB	0.87146	0.80845	0.92805	0.67497	0.78018
		Op. generalizada de fechamento	0.87381	0.80523	0.93206	0.68166	0.78435

de avaliação foram melhores em comparação com os métodos sem o aprimoramento. Para o conjunto de imagens com pelos, não houve um método de detecção de pelos claramente superior aos outros. O método de detecção de pelos *bottom hat* RGB se demonstrou o melhor nas métricas de acurácia e especificidade, enquanto a operação generalizada de fechamento obteve os melhores resultados no índice de Jaccard e no coeficiente de Dice. No conjunto de imagens sem pelos, os resultados das métricas de avaliação para os métodos com as máscaras de detecção aprimoradas também foram melhores. Neste conjunto de imagens, o método de detecção de pelos operação generalizada de fechamento apresentou os melhores resultados em todas as métricas de avaliação exceto na sensibilidade, onde o método *bottom hat* RGB obteve um melhor resultado.

Apesar de ter obtido o melhor resultado nas métricas de avaliação, o método de remoção utilizando a operação generalizada de fechamento como detecção de pelos foi o que obteve o maior tempo de execução, como pode ser observado na Tabela 5.3. Entretanto, este tempo

Tabela 5.3: Tempos de execução dos experimentos realizados utilizando *inpainting* por substituição pelo vizinho mais próximo.

	Aprimoramento	Detecção dos pelos	Tempo de execução (segundos)		
			Remoção de pelos	Segmentação da lesão	Total
Imagens com pelos	Não	Bottom Hat Y Channel	0.55868	205.23853	205.79718
		Bottom Hat RGB	0.64350	215.04701	215.69050
		Op. generalizada de fechamento	0.71239	202.03848	202.75087
	Sim	Bottom Hat Y Channel	1.23538	228.08198	229.31736
		Bottom Hat RGB	1.20808	230.01657	231.22465
		Op. generalizada de fechamento	2.07314	237.35402	239.42716
Imagens sem pelos	Não	Bottom Hat Y Channel	0.46943	211.08194	211.55137
		Bottom Hat RGB	0.54399	232.39243	232.93642
		Op. generalizada de fechamento	0.45417	195.50243	195.9566
	Sim	Bottom Hat Y Channel	0.55670	219.70878	220.26548
		Bottom Hat RGB	0.62533	231.80906	232.43439
		Op. generalizada de fechamento	0.77812	206.02217	206.80029

de execução maior resultou em uma segmentação da lesão mais rápida do que os outros métodos de remoção de pelo, logo este método obteve os melhores resultados quando avaliado juntamente ao tempo de execução da segmentação da lesão.

5.3.3 Segmentação da lesão com remoção de pelos: *inpainting* baseado em exemplos

O método de *inpainting* baseado em exemplos apresentou resultados semelhantes aos do método discutido na seção anterior. Como pode ser observado na Tabela 5.4, a operação generalizada de fechamento obteve os melhores resultados dentre os métodos de detecção de pelos em ambos conjuntos de imagens. O resultado da aplicação deste método pode ser observado na Figura 5.3.

Por ser um método mais complexo que a substituição pelo vizinho mais próximo, era es-

perado que este método obteria resultados melhores, o que não foi confirmado nos resultados obtidos nesse trabalho. Um dos possíveis motivos deste método ter demonstrado uma performance abaixo do esperado pode ser atribuído às máscaras geradas na detecção dos pelos, pois as mesmas podem não ter sido geradas de forma que as regiões dos pelos fossem finas demais para este método ser efetivo. Isto pode ser confirmado através da melhora nos resultados das métricas das máscaras com aprimoramento.

Como apresentado na Tabela 5.4, quase todos resultados das imagens com pelos melhoraram após o aprimoramento das máscaras de detecção de pelos. Para o conjunto de imagens com pelos o melhor método de detecção de pelos foi operação generalizada de fechamento, tanto nos experimentos com aprimoramento da máscara quanto nos experimentos sem o aprimoramento da máscara. Já para o conjunto de imagens sem pelo, o método de detecção de pelos *bottom hat* RGB se mostrou melhor que a operação generalizada de fechamento nos experimentos com o aprimoramento da máscara. Entretanto, nos experimentos sem o aprimoramento das máscaras para o conjunto de imagens sem pelos, o método de detecção de pelos operação generalizada de fechamento obteve os melhores resultados.




Figura 5.3: Aplicação do método de remoção de pelos utilizando o *inpainting* baseado em exemplos: (a) Imagem original, (b) imagem após a remoção dos pelos.

Contudo, quanto ao tempo de execução, o método que se destacou foi o *bottom hat* RGB, já que o mesmo resultou em um melhor tempo de execução da segmentação da lesão, como pode ser observado na Tabela 5.5. Entretanto, mesmo com um maior tempo de execução, o método de detecção de pelos operação generalizada de fechamento ainda pode ser considerado como melhor pois a disparidade de tempo do mesmo com o método *bottom hat* RGB é pequena considerando o ganho demonstrado nos resultados das métricas de avaliação presentes na Tabela 5.4.

Tabela 5.4: Resultados das métricas de avaliação para a segmentação da lesão com *inpainting* baseado em exemplos.

		Métricas de Avaliação					
	Aprimoramento	Deteção dos pelos	ACC	SE	SP	J	DSC
Imagens com pelos	Não	Bottom Hat Y Channel	0.84172	0.75173	0.89379	0.57198	0.69280
		Bottom Hat RGB	0.84699	0.74111	0.89999	0.57033	0.69116
		Op. generalizada de fechamento	0.84826	0.74667	0.90058	0.57611	0.68931
	Sim	Bottom Hat Y Channel	0.85222	0.76666	0.90769	0.61191	0.73185
		Bottom Hat RGB	0.85229	0.76560	0.90825	0.61285	0.73228
		Op. generalizada de fechamento	0.87693	0.78265	0.93842	0.66454	0.78475
Imagens sem pelos	Não	Bottom Hat Y Channel	0.87329	0.80802	0.92958	0.67493	0.78102
		Bottom Hat RGB	0.87335	0.80840	0.92958	0.67533	0.78124
		Op. generalizada de fechamento	0.87450	0.80691	0.93231	0.67988	0.78363
	Sim	Bottom Hat Y Channel	0.87194	0.80811	0.92801	0.67478	0.78016
		Bottom Hat RGB	0.87221	0.80906	0.92802	0.67575	0.78074
		Op. generalizada de fechamento	0.87262	0.82440	0.91256	0.65371	0.75547

Tabela 5.5: Tempos de execução dos experimentos realizados utilizando *inpainting* baseado em exemplos.

	Aprimoramento	Detecção dos pelos	Tempo de execução (segundos)		
			Remoção de pelos	Segmentação da lesão	Total
Imagens com pelos	Não	Bottom Hat Y Channel	19.13744	214.52968	233.66712
		Bottom Hat RGB	18.25196	214.38079	232.63275
		Op. generalizada de fechamento	37.14738	211.75204	248.89942
	Sim	Bottom Hat Y Channel	23.73612	216.20411	239.94023
		Bottom Hat RGB	21.29418	215.13774	236.43192
		Op. generalizada de fechamento	43.95230	207.06459	251.01689
Imagens sem pelos	Não	Bottom Hat Y Channel	13.07482	212.07867	225.15349
		Bottom Hat RGB	13.12107	193.66864	206.78971
		Op. generalizada de fechamento	29.69954	207.77084	237.47038
	Sim	Bottom Hat Y Channel	15.67203	213.99646	229.66849
		Bottom Hat RGB	18.75510	222.91037	241.66547
		Op. generalizada de fechamento	32.64225	214.51558	247.15783

Capítulo 6

Conclusão

Existem diversas formas de resolver o problema de remoção de pelos em imagens dermatoscópicas. Após a revisão de literatura pôde ser observado que o uso da morfologia é muito presente na fase de detecção dos algoritmos de remoção de pelos (Lee et al., 1997; Xie et al., 2009; Zaqout, 2017; Bibiloni et al., 2017). Também foi observado que se mostra necessário um passo para aprimorar as máscaras geradas pelo passo de detecção dos pelos. Quanto a reparação da imagem com os pelos removidos, as técnicas variam muito: de técnicas mais triviais, como a substituição pelo vizinho mais próximo (Lee et al., 1997), até técnicas mais complexas, como a difusão anisotrópica (Xie et al., 2009).

Por outro lado, não foram encontrados experimentos que confirmem que a remoção de pelos realmente é desnecessária, ou se a aplicação da remoção de pelos pode melhorar os resultados. Por este motivo, o presente trabalho teve como objetivo verificar se a remoção de pelos ajuda na segmentação de lesões de pele em imagens dermatoscópicas. Na pesquisa realizada no presente trabalho, foi observado que métodos de segmentação e classificação de lesões de pele geralmente consideram desnecessário a remoção de pelos (Youssef et al., 2018; Fornaciali et al., 2016).

Dos experimentos realizados neste trabalho, o método de remoção de pelos que se destacou mais foi o método utilizando o *inpainting* baseado em exemplos tendo a detecção de pelos sendo realizada pelo método operação generalizada de fechamento com o aprimoramento da máscara gerada. A segmentação da lesão teve uma aumento de cerca de 5% na acurácia e 12% no índice de Jaccard, indicando que a remoção de pelos melhorou o resultado da segmentação da lesão. Além disto, este método alterou os resultados das métricas do conjunto de imagens sem pelos, indicando que o mesmo não afeta negativamente a segmentação da lesão em imagens que não contem pelos. Portanto, dado os resultados do presente trabalho, pode-se concluir que utilizar a remoção de pelos como um pré-processamento para segmentação de lesões de pele em imagens dermatoscópicas, pode indicar melhora no resultado da segmentação da lesão das imagens com pelos.

Após os experimentos realizados no presente trabalho foi identificado que os resultados

poderiam ser melhorados a partir da aplicação de outros métodos de segmentação ou se mais experimentos fossem realizados com diferentes conjuntos de imagens. O método de segmentação proposto por Chan e Vese (2001) apesar de adequado para o problema abordado, produziu regiões com bordas irregulares, ou seja, contendo falhas, o que afetou negativamente os resultados obtidos. Atualmente, arquiteturas de *deep learning*, tais como, redes neurais convolucionais, vem apresentando bons resultados na segmentação de lesões e detecção e remoção de pelos (Badrinarayanan et al., 2017; Talavera-Martínez et al., 2020). Logo realizar novos experimentos utilizando algumas destas arquiteturas para detecção e remoção de pelos pode ser uma boa proposta para possíveis trabalhos futuros neste tema.

Referências Bibliográficas

- Abbas, Q.; Celebi, M. E. e García, I. F. (2011). Hair removal methods: A comparative study for dermoscopy images. *Biomedical Signal Processing and Control*, 6(4):395–404.
- Abbas, Q.; Emre Celebi, M.; Garcia, I. F. e Ahmad, W. (2013a). Melanoma recognition framework based on expert definition of abcd for dermoscopic images. *Skin Research and Technology*, 19(1):e93–e102.
- Abbas, Q.; Garcia, I. F.; Emre Celebi, M.; Ahmad, W. e Mushtaq, Q. (2013b). A perceptually oriented method for contrast enhancement and segmentation of dermoscopy images. *Skin Research and Technology*, 19(1):e490–e497.
- Acharya, T. e Ray, A. K. (2005). *Image processing: principles and applications*. John Wiley & Sons. 425 p.
- Azevedo-Marques, P. M. (2001). Diagnóstico auxiliado por computador na radiologia. *Radiologia Brasileira*, 34(5):285–293.
- Badrinarayanan, V.; Kendall, A. e Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 39(12):2481–2495.
- Bibiloni, P.; González-Hidalgo, M. e Massanet, S. (2017). Skin hair removal in dermoscopic images using soft color morphology. In *Conference on Artificial Intelligence in Medicine in Europe*, pp. 322–326, Vienna, Austria. Springer.
- Bornemann, F. e März, T. (2007). Fast image inpainting based on coherence transport. *Journal of Mathematical Imaging and Vision*, 28(3):259–278.
- Chan, T. F. e Vese, L. A. (2001). Active contours without edges. *IEEE Transactions on image processing*, 10(2):266–277.
- Cheng, J.-Z.; Ni, D.; Chou, Y.-H.; Qin, J.; Tiu, C.-M.; Chang, Y.-C.; Huang, C.-S.; Shen, D. e Chen, C.-M. (2016). Computer-aided diagnosis with deep learning architecture: applications to breast lesions in us images and pulmonary nodules in ct scans. *Scientific reports*, 6:24454.

- Codella, N.; Rotemberg, V.; Tschandl, P.; Celebi, M. E.; Dusza, S.; Gutman, D.; Helba, B.; Kalloo, A.; Liopyris, K.; Marchetti, M. et al. (2019). Skin lesion analysis toward melanoma detection 2018: A challenge hosted by the international skin imaging collaboration (isic). *arXiv preprint arXiv:1902.03368*.
- Codella, N. C.; Gutman, D.; Celebi, M. E.; Helba, B.; Marchetti, M. A.; Dusza, S. W.; Kalloo, A.; Liopyris, K.; Mishra, N.; Kittler, H. et al. (2018). Skin lesion analysis toward melanoma detection: A challenge at the 2017 international symposium on biomedical imaging (isbi), hosted by the international skin imaging collaboration (isic). In *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, pp. 168–172. IEEE.
- Criminisi, A.; Pérez, P. e Toyama, K. (2004). Region filling and object removal by exemplar-based image inpainting. *IEEE Transactions on image processing*, 13(9):1200–1212.
- Cunha, A. L. (2016). Introdução à visão computacional. https://www.stt.eesc.usp.br/andre/palestras/CEFET-MG/01_Intro.html, Acessado em 12 de abril de 2021.
- Dice, L. R. (1945). Measures of the amount of ecologic association between species. *Ecology*, 26(3):297–302.
- Dreiseitl, S.; Binder, M.; Hable, K. e Kittler, H. (2009). Computer versus human diagnosis of melanoma: evaluation of the feasibility of an automated diagnostic system in a prospective clinical trial. *Melanoma research*, 19(3):180–184.
- Fawcett, T. (2004). Roc graphs: Notes and practical considerations for researchers. *Machine learning*, 31(1):1–38.
- Fornaciali, M.; Carvalho, M.; Bittencourt, F. V.; Avila, S. e Valle, E. (2016). Towards automated melanoma screening: Proper computer vision & reliable results. *arXiv preprint arXiv:1604.04024*.
- Gonzalez, R. C. e Woods, R. E. (2000). *Processamento de imagens digitais*, p. 501. Edgard Blucher, São Paulo, São Paulo, BR.
- Ibraheem, N. A.; Hasan, M. M.; Khan, R. Z. e Mishra, P. K. (2012). Understanding color models: a review. *ARPJ Journal of science and technology*, 2(3):265–275.
- INCA (2018). Câncer de pele não melanoma. Disponível em: <https://www.inca.gov.br/tipos-de-cancer/cancer-de-pele-nao-melanoma> [Acessado em 5 de Setembro de 2019].
- Johr, R. H. (2002). Dermoscopy: alternative melanocytic algorithms—the abcd rule of dermoscopy, menzies scoring method, and 7-point checklist. *Clinics in dermatology*, 20(3):240–247.

- Kiani, K. e Sharafat, A. R. (2011). E-shaver: An improved dullrazor® for digitally removing dark and light-colored hairs in dermoscopic images. *Computers in biology and medicine*, 41(3):139–145.
- Lee, T.; Ng, V.; Gallagher, R.; Coldman, A. e Mclean, D. (1997). Dullrazor®: A software approach to hair removal from images. *Computers in Biology and Medicine*, 27(6):533–543.
- Maglogiannis, I. e Delibasis, K. K. (2015). Enhancing classification accuracy utilizing globules and dots features in digital dermoscopy. *Computer methods and programs in biomedicine*, 118(2):124–133.
- Maragos, P. (2005). Morphological filtering for image enhancement and feature detection. *The Image and Video Processing Handbook*, 2:135–156.
- Metcalf, L. e Casey, W. (2016). *Cybersecurity and Applied Mathematics*, p. 183. Syngress, Cambridge, MA, USA.
- Møllersen, K.; Zortea, M.; Hindberg, K.; Schopf, T. R.; Skrøvseth, S. O. e Godtliebsen, F. (2015). Improved skin lesion diagnostics for general practice by computer-aided diagnostics. In *Dermoscopy Image Analysis*, pp. 257–302. CRC Press, Boca Raton.
- Nguyen, N. H.; Lee, T. K. e Atkins, M. S. (2010). Segmentation of light and dark hair in dermoscopic images: a hybrid approach using a universal kernel. In *Medical Imaging 2010: Image Processing*, volume 7623, p. 76234N, San Diego, CA. International Society for Optics and Photonics.
- Oliveira, R. B.; Mercedes Filho, E.; Ma, Z.; Papa, J. P.; Pereira, A. S. e Tavares, J. M. R. (2016). Computational methods for the image segmentation of pigmented skin lesions: a review. *Computer methods and programs in biomedicine*, 131:127–141.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1):62–66.
- Pathan, S.; Prabhu, K. G. e Siddalingaswamy, P. (2018). Hair detection and lesion segmentation in dermoscopic images using domain knowledge. *Medical & biological engineering & computing*, 56(11):2051–2065.
- Perrinaud, A.; Gaide, O.; French, L.; Saurat, J.-H.; Marghoob, A. e Braun, R. (2007). Can automated dermoscopy image analysis instruments provide added benefit for the dermatologist? a study comparing the results of three systems. *British Journal of Dermatology*, 157(5):926–933.
- Rezze, G. G.; de Sá, B. C. S. e Neves, R. I. (2006). Dermatoscopia: o método de análise de padrões. *Anais Brasileiros de Dermatologia*, 3:261–8.

- Schmid-Saugeona, P.; Guillodb, J. e Thirana, J.-P. (2003). Towards a computer-aided diagnosis system for pigmented skin lesions. *Computerized Medical Imaging and Graphics*, 27(1):65–78.
- Sobel, I. (1990). An isotropic 3×3 gradient operator, machine vision for three-dimensional scenes. *Freeman, Hebert, Academic Pres, NY*, pp. 376–379.
- Steger, C. (1998). An unbiased detector of curvilinear structures. *IEEE Transactions on pattern analysis and machine intelligence*, 20(2):113–125.
- Talavera-Martínez, L.; Bibiloni, P. e González-Hidalgo, M. (2020). Hair segmentation and removal in dermoscopic images using deep learning. *IEEE Access*.
- Tkalcic, M. e Tasic, J. F. (2003). *Colour spaces: perceptual, historical and applicational background*, volume 1. IEEE.
- Toossi, M. T. B.; Pourreza, H. R.; Zare, H.; Sigari, M.-H.; Layegh, P. e Azimi, A. (2013). An effective hair removal algorithm for dermoscopy images. *Skin Research and Technology*, 19(3):230–235.
- Tschanl, P.; Rosendahl, C. e Kittler, H. (2018). The ham10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific data*, 5:180161.
- Xie, F.-Y.; Qin, S.-Y.; Jiang, Z.-G. e Meng, R.-S. (2009). PDE-based unsupervised repair of hair-occluded information in dermoscopy images of melanoma. *Computerized Medical Imaging and Graphics*, 33(4):275–282.
- Yang, L.; Wu, X.; Zhao, D.; Li, H. e Zhai, J. (2011). An improved prewitt algorithm for edge detection based on noised image. In *4th International Congress on Image and Signal Processing*, volume 3, pp. 1197–1200, Shanghai, China. IEEE.
- Youssef, A.; Bloisi, D. D.; Muscio, M.; Pennisi, A.; Nardi, D. e Facchiano, A. (2018). Deep convolutional pixel-wise labeling for skin lesion image segmentation. In *2018 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, pp. 1–6, Rome, Italy. IEEE.
- Zaqout, I. S. (2017). An efficient block-based algorithm for hair removal in dermoscopic images. *Computer Optics 2017*, 41(4):521–527.
- Zhou, H.; Chen, M.; Gass, R.; Rehg, J. M.; Ferris, L.; Ho, J. e Drogowski, L. (2008). Feature-preserving artifact removal from dermoscopy images. In *Medical Imaging 2008: Image Processing*, volume 6914, p. 69141B, San Diego, California, United States. International Society for Optics and Photonics.