

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE MINAS GERAIS
Programa de Pós-Graduação em Engenharia Elétrica

Rodolfo Herman Lara e Silva

**MENSURAÇÃO AUTOMÁTICA DE ÚLCERAS POR PRESSÃO
UTILIZANDO MÁQUINAS DE VETORES DE SUPORTE E GRABCUT**

Belo Horizonte

2020

Rodolfo Herman Lara e Silva

**MENSURAÇÃO AUTOMÁTICA DE ÚLCERAS POR PRESSÃO
UTILIZANDO MÁQUINAS DE VETORES DE SUPORTE E GRABCUT**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica de Minas Gerais, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Alexei Manso Corrêa Machado

Linha de pesquisa: Visão Computacional, Processamento de Imagens Digitais e Aprendizagem de Máquina

Belo Horizonte

2020

FICHA CATALOGRÁFICA

Elaborada pela Biblioteca da Pontifícia Universidade Católica de Minas Gerais

S586m	<p>Silva, Rodolfo Herman Lara e Mensuração automática de úlceras por pressão utilizando máquinas de vetores de suporte e Grabcut / Rodolfo Herman Lara e Silva. Belo Horizonte, 2020. 77 f. : il.</p> <p>Orientador: Alexei Manso Corrêa Machado Dissertação (Mestrado) – Pontifícia Universidade Católica de Minas Gerais. Programa de Pós-Graduação em Engenharia Elétrica</p> <p>1. Úlcera de pressão - Diagnóstico. 2. Software. 3. Processamento de imagens - Técnicas digitais. 4. Teoria dos grafos. 5. Diagnóstico por imagem. 6. Ferimentos e lesões - Tratamento. 7. Inteligência computacional. 8. Imagens digitais. I. Machado, Alexei Manso Corrêa. II. Pontifícia Universidade Católica de Minas Gerais. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.</p> <p>CDU: 615.849</p>
-------	---

Rodolfo Herman Lara e Silva

Mensuração Automática de Úlceras por Pressão Utilizando Máquinas de Vetores de Suporte e GrabCut

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica de Minas Gerais, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Linha de pesquisa: Visão Computacional, Processamento de Imagens Digitais e Aprendizagem de Máquina

Prof. Dr. Alexei Manso Corrêa Machado (Orientador) — PUC Minas

Prof. Dr. Mario Fernando Montenegro Campos — UFMG

Prof. Dr. Silvio Jamil Ferzoli Guimarães — PUC Minas

Prof^ª. Dr^a. Zélia Myriam Assis Peixoto — PUC Minas

Belo Horizonte, 31 de julho de 2020

Aos meus pais, Mike e Ariadne, ao meu irmão, Rafael, e aos meus amigos.

AGRADECIMENTOS

Gostaria de agradecer primeiramente a Deus por me conceder este caminho de estudos e por sempre me ajudar a superar os desafios em minha vida.

Eu gostaria de expressar minha gratidão às seguintes instituições e pessoas:

À PUC Minas, pela minha formação e oportunidades fornecidas.

À Coordenadoria de Aperfeiçoamento de Pessoal de Nível Superior – CAPES pela bolsa de estudos concedida.

Ao meu orientador, Prof. Dr. Alexei Manso Corrêa Machado, por acreditar em meu trabalho, pela disposição e tempo gastos em me ajudar, pela dedicação e conhecimentos transmitidos.

Aos professores e demais funcionários do Programa de Pós-Graduação em Engenharia Elétrica da PUC Minas, pois sem eles não existiria o programa.

Aos professores da graduação do curso de Ciência da Computação pelos conhecimentos transmitidos e que foram primordiais para que eu ingressasse no Programa de Pós-Graduação em Engenharia Elétrica.

Ao meu pai, Mike Herman Pereira da Silva, à minha mãe, Ariadne Lara da Silva, e ao meu irmão, Rafael Felipe Lara e Silva, pelo apoio e por me oferecerem a oportunidade de estudar. Aos meus familiares e amigos. Em especial ao meu amigo Gustavo Henrique Toledo dos Santos, por me incentivar no início da minha caminhada em 2012. Ao meu amigo enfermeiro Leonardo Brasil Oliveira Costa, por me apresentar o tema úlceras por pressão, onde eu realizo estudos e trabalhos acadêmicos.

“O fracasso é a oportunidade de se começar de novo inteligentemente.”

Henry Ford

RESUMO

Úlceras por pressão constituem um sério problema de saúde pública. Essas lesões são regiões de trauma causadas por uma pressão contínua aplicada aos tecidos moles entre uma proeminência óssea e uma superfície dura ou dispositivos médicos. O acompanhamento da evolução da cicatrização pode ser realizado por técnicas manuais de avaliação de área, que incluem o uso de réguas e decalques em contato direto com a lesão, sendo altamente imprecisas e subjetivas. Este estudo apresenta uma abordagem baseada no classificador por Máquinas de Vetores de Suporte (SVM) em combinação com uma versão modificada do método GrabCut para a medição automática da área afetada por úlceras por pressão em imagens digitais. Três métodos de segmentação de região usando a estratégia de *superpixels* foram avaliados. Vários descritores de cor e textura foram extraídos de cada *superpixel*, formando os vetores de características usados pelo classificador. Os vetores de características passam pela técnica de redução de dimensionalidade, mantendo apenas as características com informações relevantes para o classificador. Uma etapa de pós-classificação é aplicada com o uso do método de segmentação GrabCut para extrair a área afetada pela úlcera do resto da imagem. Os experimentos que embasaram o estudo foram realizados em um conjunto de dados de 105 imagens de úlceras por pressão extraídas de um conjunto de dados público. O método proposto alcançou acurácia de 96%, sensibilidade de 94%, especificidade de 97% e interseção sobre união de 89%.

Palavras-chaves: Úlceras por pressão. Análise de imagens médicas. Segmentação de imagens digitais. Aprendizagem de máquinas. Máquinas de Vetores de Suporte (SVM).

ABSTRACT

Pressure ulcers are a serious public health problem. These injuries are regions of trauma caused by continuous pressure applied to the soft tissues between a bony prominence and a hard surface or medical devices. The follow-up of the healing evolution can be performed by manual techniques of area evaluation, which include the use of rulers and adhesive labels in direct contact with the lesion, being highly inaccurate and subjective. This study presents an approach based on the Support Vector Machine (SVM) classifier in combination with a modified version of the GrabCut method for the automatic measurement of the area affected by pressure ulcers in digital images. Three methods of region segmentation using the *superpixel* strategy were evaluated. Several color and texture descriptors were extracted from each *superpixel*, forming the feature vectors used by the classifier. The feature vectors underwent dimensionality reduction techniques, maintaining only the feature with information relevant to the classifier. A post classification step was applied using the GrabCut segmentation method to extract the area affected by the ulcer from the rest of the image. Experiments were conducted on a set of 105 pressure ulcer images extracted from a public data set. The proposed method achieved accuracy of 96%, sensitivity of 94%, specificity of 97% and intersection-over-union of 89%.

Key-words: Pressure ulcers. Medical image analyses. Digital image segmentation. Machine learning. Support Vector Machines (SVM).

LISTA DE ILUSTRAÇÕES

Figura 1 – Diagrama do processo de segmentação da úlcera por pressão	22
Figura 2 – Estrutura da pele	29
Figura 3 – Fisiopatologia da úlcera por pressão	30
Figura 4 – Estágios da úlcera por pressão	31
Figura 5 – Técnica de mensuração por régua	32
Figura 6 – Técnica de mensuração por decalques	33
Figura 7 – Espaço de cores RGB	35
Figura 8 – Espaço de cores $L^*a^*b^*$	36
Figura 9 – Espaço de cores Luv	37
Figura 10 – Espaço de cores HSV	37
Figura 11 – Segmentação com a estratégia por superpixels	38
Figura 12 – Esquema de criação do LBPH	43
Figura 13 – Exemplo de estrutura piramidal <i>wavelet</i>	44
Figura 14 – Dados linearmente separáveis versus não linearmente separáveis	45
Figura 15 – Ilustração do grafo S-T e seu corte mínimo	47
Figura 16 – Segmentação com o método GrabCut	47
Figura 17 – Exemplo de restauração de uma imagem utilizando o método <i>inpainting</i>	48
Figura 18 – Exemplo de reflexos de luz nas imagens de úlcera	49
Figura 19 – Processo de remoção e reconstrução das regiões de reflexos de luz	50
Figura 20 – Processo de rotulação dos superpixels	52
Figura 21 – Esquema de aplicação da DWT em uma imagem digital	54
Figura 22 – Diagrama de treinamento e classificação com SVM	57
Figura 23 – Processo de criação da máscara e a segmentação da imagem com os métodos SVM e GrabCut	58
Figura 24 – Exemplos de segmentação ineficaz	64
Figura 25 – Exemplos de segmentação eficaz	65
Figura 26 – Exemplo da eficácia da segmentação com GrabCut utilizando SEEDS	66
Figura 27 – Exemplo de segmentação de imagem com úlcera composta	68

LISTA DE TABELAS

Tabela 1 – Atributos que melhor representam os superpixels	55
Tabela 2 – Resultados das métricas de avaliação	62
Tabela 3 – Métricas de desempenho relatadas pelos métodos na literatura	67
Tabela 4 – Métricas de desempenho entre os trabalhos desenvolvidos	72

SUMÁRIO

1	INTRODUÇÃO	21
1.1	Motivação	21
1.2	Objetivo	22
1.3	Estrutura do Trabalho	23
2	TRABALHOS RELACIONADOS	25
3	ÚLCERAS POR PRESSÃO	29
3.1	Anatomia da Pele	29
3.2	Fisiopatologia da Úlcera por Pressão	30
3.3	Técnicas Tradicionais de Mensuração	32
4	DESCRIÇÃO E SEGMENTAÇÃO DE ÚLCERAS	35
4.1	Espaço de Cores	35
4.1.1	<i>Espaço de Cores RGB</i>	35
4.1.2	<i>Espaço de Cores $L^*a^*b^*$</i>	36
4.1.3	<i>Espaço de Cores Luv</i>	36
4.1.4	<i>Espaço de Cores HSV</i>	37
4.1.5	<i>Espaço de Cores NRGB</i>	38
4.2	Superpixels	38
4.2.1	<i>SLIC</i>	39
4.2.2	<i>LSC</i>	39
4.2.3	<i>SEEDS</i>	39
4.3	Extração de Descritores	40
4.3.1	<i>Descritores de Cor</i>	40
4.3.2	<i>Descritores de Textura</i>	41
4.3.2.1	Haralick	41
4.3.2.2	Local Binary Patterns Histograms (LBPH)	42
4.3.2.3	Transformada Wavelet Discreta (DWT)	43
4.4	Máquinas de Vetores de Suporte (SVM)	44
4.5	GrabCut	46
4.6	Inpainting	48
5	MATERIAIS E MÉTODOS	49
5.1	Conjunto de Dados	49
5.2	Pré-processamento dos Dados	49
5.3	Segmentação em Superpixels	51
5.4	Extração dos Descritores de Cor e Textura	51

5.5	Normalização dos Descritores	54
5.6	Redução de Dimensionalidade	55
5.7	SVM - Parametrização e Classificação	56
5.8	Segmentação com GrabCut	57
5.9	Métricas de Avaliação	59
6	EXPERIMENTOS	61
7	DISCUSSÃO	67
8	CONCLUSÃO	71
	REFERÊNCIAS	73

1 INTRODUÇÃO

1.1 Motivação

Úlcera por pressão é um tipo de lesão crônica causada por pressão contínua e prolongada aplicada à pele e tecidos adjacentes resultando na obstrução do fluxo sanguíneo e levando à morte celular. Esses tipos de lesões são decorrentes da excessiva compressão dos tecidos moles contra proeminências ósseas e superfícies duras ou dispositivos médicos. Elas geralmente se desenvolvem na metade inferior do corpo: dois terços ao redor da pelve e um terço nos membros inferiores (GREY; HARDING; ENOCH, 2006). Pessoas acometidas por essas lesões têm seus tempos de internação aumentados, favorecendo o surgimento de novos agravos que são um grande fator de custo para o paciente e para os sistemas públicos e privados de saúde (DEMARRÉ et al., 2015). Além disso, são uma das principais causas do aumento da morbidade e mortalidade em pacientes acamados, portadores de doenças crônicas-degenerativas e idosos.

Entender e conhecer as úlceras por pressão, suas causas e fatores de risco, permitem aos enfermeiros implementarem melhores ações preventivas e terapêuticas. A avaliação das úlceras envolve métodos invasivos e não invasivos para monitorar o processo de cicatrização, estimando-se a alteração na área, profundidade e tipos de tecidos que caracterizam a lesão. A redução da área da úlcera é um dos indicadores mais importantes da cicatrização (GETHIN, 2006). Profissionais de saúde avaliam a área das úlceras principalmente por inspeção visual, com auxílio de régua e decalques em contato direto com a úlcera, o que pode causar infecções, desconforto ou piorar a condição clínica do paciente. Além disso, essas técnicas são geralmente imprecisas, subjetivas e sofrem com a falta de padronização entre os profissionais da saúde (KEAST et al., 2004).

A cicatrização é um evento celular complexo e composto por três fases sobrepostas distintas: inflamatória, proliferação e maturação, iniciadas imediatamente após a lesão na pele (Ministério da Saúde do Brasil, 2002). Durante a cicatrização, o leito da lesão pode apresentar uma variedade de cores que geralmente refletem a mistura dos tecidos de granulação (vermelho ou rosa escuro), esfacelo (amarelo, cinza ou esverdeado) e escara (marrom ou preto). Inicialmente, a cicatrização tem aspecto plano, enrijecendo-se após um determinado tempo, ocorrendo sua redução no sentido da periferia para o centro. Devido à complexidade, a cicatrização das lesões pode ser mais bem acompanhada e descrita usando-se escalas de monitoramento (EDSBERG et al., 2016).

O desenvolvimento de métodos computacionais para realizar avaliações e acompanhamentos clínicos das úlceras por meio de imagens digitais tem se tornado uma alternativa importante, uma vez que essas técnicas podem fornecer informações para uma análise mais confiável e objetiva (JØRGENSEN et al., 2016). Dessa forma, os profissionais de saúde podem elaborar estratégias para acelerar o processo de cicatrização ou até mesmo mudar

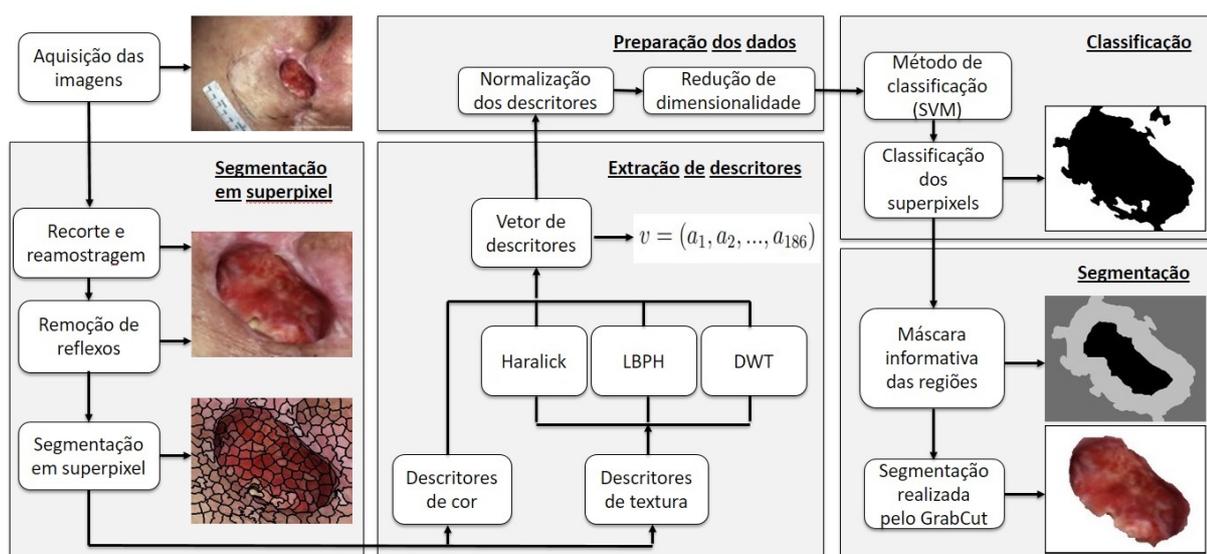
a abordagem do tratamento de maneira mais precisa. Os trabalhos científicos disponíveis na literatura (WANG et al., 2015), (SILVA; MACHADO, 2018) e (ZAHIA et al., 2018), se concentram em realizar segmentação da úlcera e determinar sua área, classificar os tipos de tecidos presentes em seu leito e monitorar a taxa de cicatrização da lesão durante o período de tratamento dos pacientes.

1.2 Objetivo

O objetivo geral deste trabalho é desenvolver um método capaz de realizar a segmentação de úlceras por pressão em imagens digitais de forma automática com vistas à extração da área da lesão, permitindo o monitoramento da evolução cicatricial. A proposta envolve o classificador por Máquinas de Vetores de Suporte (SVM) em combinação com uma versão modificada do método de segmentação GrabCut.

A Figura 1 descreve o processo de segmentação proposto¹ e que pode ser dividido em cinco partes, incluindo segmentação em superpixels, técnicas de processamento para a extração de descritores de cor e textura, preparação dos dados, classificação e por fim a segmentação de feridas com o método GrabCut. A segmentação em superpixels envolve etapas de pré-processamento para evitar artefatos nas imagens, como reflexo de luz. Em seguida, as imagens são particionadas em pequenas regiões com o objetivo de extrair descritores a serem utilizados pelo classificador SVM. A preparação dos dados é frequentemente usada em algoritmos de aprendizado de máquina para normalizar os descritores para uma escala comum e remover informações redundantes e irrelevantes. A

Figura 1 – Diagrama do processo de segmentação da úlcera por pressão.



Fonte: Elaborado pelo Autor.

¹O código fonte da implementação do trabalho pode ser acessado em <<https://github.com/RodolfoHerman/ulcer-segmentation>>.

classificação determina a identificação das regiões de úlcera e pele na imagem. Por fim, a segmentação que visa separar o objeto de interesse do restante da imagem.

O desenvolvimento da pesquisa, bem como os testes de desempenho, foram realizados em imagens de úlcera por pressão obtidas do banco de dados público de feridas MEDETEC (MEDETEC, 2007). Experimentos do estudo de caso em 105 imagens de úlceras por pressão revelam resultados superiores aos reportados em trabalhos recentes revisados na literatura.

Além do objetivo geral descrito, esta pesquisa também contemplou os seguintes objetivos:

- Associar várias técnicas de extração de descritores de características de cor e textura para serem utilizados por algoritmos de aprendizagem de máquina.
- Identificar descritores de características apropriados por meio do algoritmo de redução de dimensionalidade Wrapper.
- Apontar as técnicas de segmentação em superpixels mais eficientes em imagens digitais de úlcera por pressão.
- Mostrar a efetividade do método GrabCut na tarefa de segmentação de objetos de interesse em imagens digitais.

1.3 Estrutura do Trabalho

Este trabalho está organizado em 8 capítulos, incluindo o atual. O Capítulo 2 apresenta uma revisão bibliográfica dos estudos publicados na literatura sobre o tema que constitui a base desta pesquisa. O Capítulo 3 aborda conceitos preliminares, apresenta os aspectos da anatomia da pele, as propriedades e características das úlceras por pressão e também as técnicas tradicionais de mensuração das úlceras. O Capítulo 4 apresenta conceitos e técnicas mais relevantes para a descrição e segmentação de úlceras. O Capítulo 5 descreve a metodologia do estudo de caso, tal como a base de dados utilizada no trabalho. O Capítulo 6 descreve os ajustes de parâmetros dos métodos e os resultados alcançados. O Capítulo 7 apresenta uma discussão comparando os resultados de trabalhos da literatura com os obtidos neste estudo. Por fim, o Capítulo 8 apresenta a conclusão e trabalhos futuros.

2 TRABALHOS RELACIONADOS

Existem várias abordagens na literatura para avaliar lesões crônicas por meio de imagens digitais. Essas abordagens podem ser divididas em (I) métodos clássicos, onde o usuário utiliza técnicas de processamento de sinais e intervém diretamente na escolha dos descritores usados, ajustando parâmetros ou indicando regiões de interesse na imagem; (II) métodos de aprendizagem de máquina, onde a intervenção do usuário na seleção de características apropriadas para o treinamento do modelo de classificação a ser utilizado é minimizado; e (III) métodos de aprendizagem profundo com redes neurais que conseguem realizar a extração de descritores de características de forma automática, mas pouco transparente e que exigem bastante processamento computacional. A seguir serão apresentados trabalhos da literatura que avaliam as lesões crônicas por meio de imagens digitais.

Perez, Gonzaga e Alves (2001) desenvolveram um método de detecção de lesões que faz o uso da diferença de cores entre a pele e a úlcera. Por ser um método semiautomático, o usuário necessita realizar marcações referentes à pele e leito da úlcera. Após isso, o método determina e seleciona qual canal de cor (R, G, B, S ou I) dos espaços de cores *RGB* e *HSI* possui o melhor contraste entre a pele e a úlcera, segmentando-a por meio de limiarização. Os autores não informaram o número de imagens e nem apresentaram as métricas de avaliação para o método. Usando uma abordagem semelhante, Papazoglou et al. (2010) propuseram um método semiautomático utilizando os espaços de cores *RGB* e $L^*a^*b^*$. O método se inicia após a seleção das regiões de interesse realizadas pelo usuário. Então, em cada componente de cor dos espaços de cores são realizadas operações matemáticas, que ao final é criada uma máscara para realizar a segmentação da lesão. Silva e Machado (2018) apresentaram uma melhoria no trabalho de Papazoglou et al. (2010), aplicaram filtros e operações morfológicas para gerar uma segmentação mais precisa da úlcera. Os testes realizados em um conjunto de dados públicos atingiram 91% de precisão, 81% de sensibilidade e 81% de acurácia. Usando agrupamento espectral Fuzzy, Dhane et al. (2017) segmentaram regiões afetadas por úlceras com base em uma matriz de similaridade Fuzzy. Os elementos da matriz são valores no nível de cinza calculados sobre a imagem. Por ser um método semiautomático, é necessário ajustar três parâmetros para que o método realize a segmentação. Por fim, após a aplicação de uma etapa de pós-processamento, os testes realizados em 70 imagens atingiram uma acurácia de 92%, sensibilidade de 87%, especificidade de 96% e interseção sobre união de 79%.

Técnicas de aprendizado de máquina (ML) também foram usadas para classificar os tipos de tecidos de lesões crônicas, além de segmentá-las. Wannous, Treuillet e Lucas (2010) usaram as Máquinas de Vetores de Suporte (SVM) para classificar os tipos de tecidos em lesões crônicas. Entre os algoritmos de clusterização avaliados no trabalho, o J-SEG (DENG; MANJUNATH, 2001) apresentou os melhores resultados e foi utilizado para clusterizar os

tipos de tecidos presentes na lesão. Extraíram-se 27 descritores de cada região clusterizada e utilizaram o SVM para classificá-las, atingindo uma média de 92% de especificidade e 77% de sensibilidade. Uma evolução do método incluiu um procedimento para estimar a profundidade das lesões (WANNOUS; LUCAS; TREUILLET, 2010). Veredas, Mesa e Morente (2009) utilizaram 113 imagens de alta resolução de úlceras por pressão em uma abordagem híbrida em cascata baseada em redes neurais e classificadores Bayesianos para realizar a classificação dos tipos de tecidos. Utilizando o algoritmo de segmentação *Mean Shift* (COMANICIU; MEER, 2002) e extraíndo 63 descritores de cada região segmentada, a abordagem proposta alcançou 94% de especificidade e 78% de sensibilidade. Uma extensão do trabalho aplicou o algoritmo *k-means* para segmentar os tipos de tecidos presentes na úlcera. Em cada região segmentada, foram extraídos 206 descritores de cor, topologia e morfologia. Avaliaram três técnicas de ML (Redes Neurais, Floresta Aleatória e SVM) para classificar cada região e a técnica por SVM alcançou o melhor resultado, reportando 88% de precisão (VEREDAS et al., 2015). Objetivando calcular a área afetada por úlcera de pé diabético, Wang et al. (2016) propuseram uma abordagem em cascata composta por dois estágios dos classificadores SVM. Capturaram 100 imagens de úlcera de pé diabético em ambiente altamente controlado a partir de um mecanismo que criaram, chamado de "caixa de captura". Então, utilizaram o método de segmentação em superpixels SLIC (*Simple Iterative Clustering*) (ACHANTA et al., 2012) para segmentar regiões nas imagens e extraíram 52 descritores de cor e textura. A segmentação com a abordagem proposta alcançou especificidade de 94% e sensibilidade de 73%.

Para superar os desafios na seleção de características e ajuste de parâmetros em métodos clássicos de ML, algoritmos de aprendizado profundo, como os baseados em redes neurais convolucionais (CNN) e totalmente conectadas (DNN), ganharam importância em problemas relacionados ao reconhecimento de objetos visuais (LITJENS et al., 2017). Lu et al. (2017) propuseram um método de correção de cor que tornam as CNN robustas quanto a inhomogeneidade presente em imagens médicas. A abordagem foi aplicada em 300 imagens de lesões crônicas e foram segmentadas utilizando uma CNN, alcançando acurácia média de 83%, mas não reportaram os escores de especificidade e sensibilidade. Usando um conjunto de dados de 650 imagens padronizadas de lesões crônicas, Wang et al. (2015) implementaram um classificador SVM e uma CNN para segmentar, identificar riscos de infecções e monitorar a evolução cicatricial. Ao segmentar as imagens, alcançaram 47,3% de interseção sobre união, mas não relataram os escores de sensibilidade e especificidade. Como a eficácia das redes neurais dependem de uma grande quantidade de dados de treinamento, Liu et al. (2017) propuseram uma rede neural leve para realizar a segmentação de feridas. Adaptaram o MobileNet (HOWARD et al., 2017) a diferentes modelos de rede *backbone*, treinando-os e testando-os em um conjunto de 950 imagens. O melhor modelo, após uma etapa de pós-processamento, obteve 98% de acurácia, 91% de sensibilidade e 93% de precisão. Zahia et al. (2018) utilizaram um conjunto de apenas 22 imagens de alta resolução

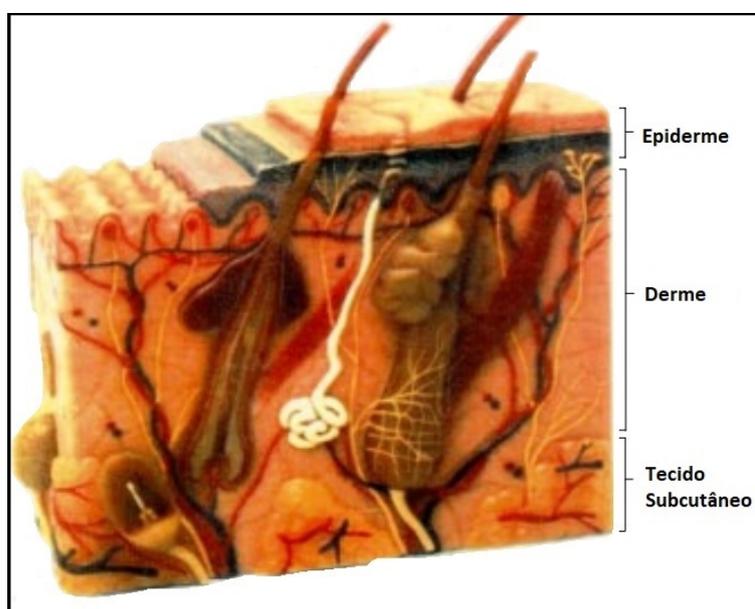
de úlceras por pressão e utilizaram CNN para classificar os tipos de tecidos presentes na úlcera. A utilização de poucas imagens só foi possível graças à alta resolução que possuíam, podendo ser recortadas em pequenos tamanhos, que serviram como entrada para treinar a CNN. Na classificação dos tipos de tecidos, os autores reportaram média global de 92% para acurácia. Li et al. (2018) observaram a necessidade de se evitar interferências do ambiente hospitalar para melhorar a eficiência das Redes Neurais Profundas (DNN) na tarefa de segmentação. Eles usaram técnicas de limiar no canal Cr do espaço de cores YCbCr para remover o fundo hospitalar das imagens. Depois disso, usaram um modelo de DNN com o MobileNet para segmentar as feridas crônicas. Por fim, usaram filtros morfológicos como etapa de pós-processamento. Os testes realizados em 950 imagens alcançaram precisão de 94,7% e interseção sobre união de 86%. Uma evolução do método incluiu um modelo de DNN baseado no mapa de localização e no *kernel* de convolução aprimorado por localização. Este modelo não precisa da etapa de remoção do fundo do ambiente hospitalar aplicada no método anterior. Os testes de segmentação atingiu precisão de 95% e interseção-sobre-união de 87% (LI et al., 2019).

3 ÚLCERAS POR PRESSÃO

3.1 Anatomia da Pele

A pele é considerada o maior órgão humano, representando 15% do peso corporal. Ela tem como funções controlar a temperatura corporal e estabelecer uma barreira entre o corpo e o meio ambiente, impedindo a penetração de microrganismos (Ministério da Saúde do Brasil, 2002). A pele é composta por três camadas, a epiderme, a derme e a hipoderme (tecido subcutâneo), ilustradas na Figura 2.

Figura 2 – Estrutura de camadas da pele.



Fonte: Ministério da Saúde do Brasil (2002).

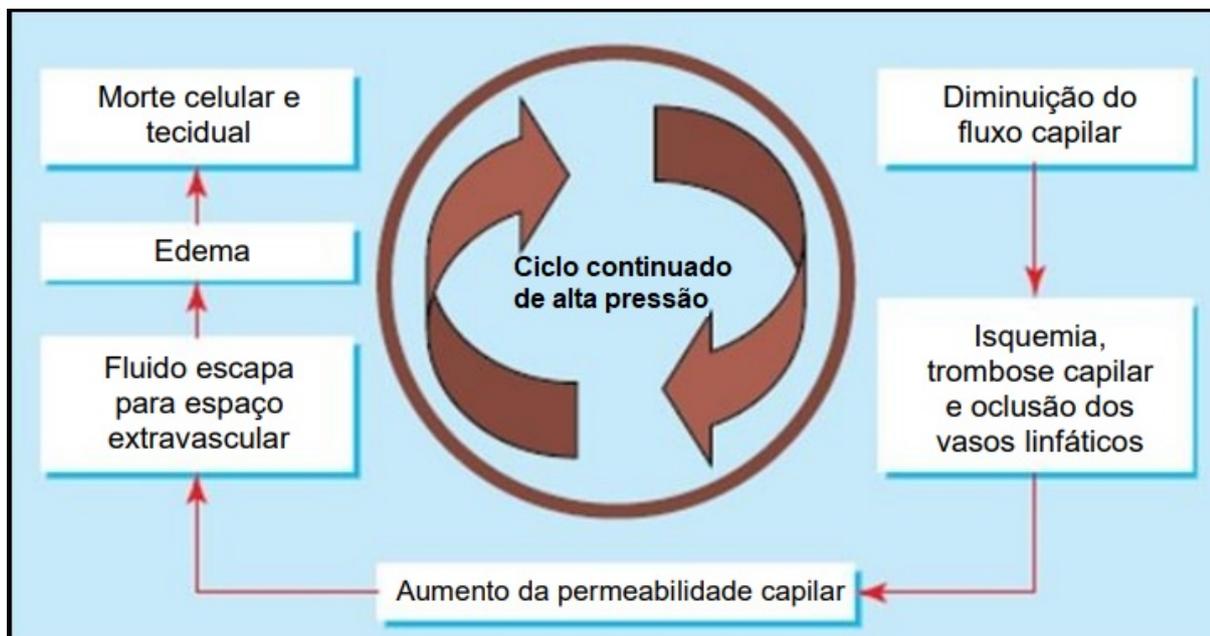
- A epiderme é a camada mais externa, sem vascularização, formada por várias camadas de células. Possui como função a proteção do organismo e impede a penetração de microrganismos ou substâncias químicas destrutivas.
- A próxima camada, a derme, localiza-se abaixo da epiderme e é constituída por tecido fibroso, fibras de colágeno, reticulares e elásticas. Nessa camada há nervos, vasos sanguíneos e linfáticos, glândulas especializadas (sebáceas, sudoríparas e folículos pilosos) e órgãos do sentido.
- A hipoderme é a camada mais profunda da pele, também é conhecida como tecido celular subcutâneo. Tem como função principal o depósito nutritivo de reserva, funcionando como isolante térmico e proteção mecânica quanto às pressões e traumatismos externos, facilitando a mobilidade da pele em relação às estruturas subjacentes.

3.2 Fisiopatologia da Úlcera por Pressão

Vários fatores são considerados para a formação das úlceras por pressão e podem ser classificados em dois grupos, os intrínsecos ou extrínsecos. No grupo dos intrínsecos destacam-se a falta de sensibilidade cutânea, imobilidade mecânica e/ou patológica, baixa pressão arteriolar, presença de incontinência fecal e/ou urinária, envelhecimento e a desnutrição da pele. Os extrínsecos estão relacionados com a exposição contínua da pele à pressão, cisalhamento, fricção e umidade. A força de cisalhamento é gerada pelo movimento do osso e tecido subcutâneo em relação à pele, que quando combinada a uma pressão mínima ocorre a oclusão dos vasos sanguíneos. O atrito entre a pele e uma superfície externa pode produzir bolhas, que por sua vez levam a erosões, iniciando ou acelerando uma úlcera por pressão. Já a umidade, devido à incontinência urinária e/ou fecal, provoca maceração ao redor da pele, aumentando os efeitos degradantes da pressão, fricção e cisalhamento (GREY; HARDING; ENOCH, 2006).

Grey, Harding e Enoch (2006) descrevem que uma pressão aplicada a pele entre 60 e 80 mmHg durante uma a duas horas sobre proeminências ósseas, leva a diminuição do fluxo sanguíneo capilar, oclusão dos vasos sanguíneos e linfáticos, isquemia e necrose tecidual da epiderme, derme e subcutâneo, resultando na formação da úlcera por pressão. A Figura 3 mostra o ciclo continuado de pressão aplicado à pele e seus efeitos.

Figura 3 – Fisiopatologia da úlcera por pressão.



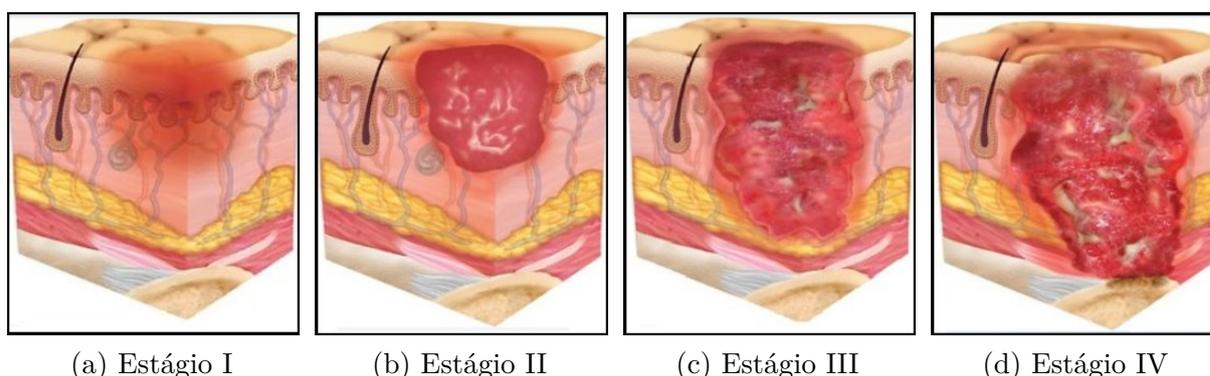
Fonte: Adaptada de Grey, Harding e Enoch (2006).

As úlceras por pressão se desenvolvem principalmente em áreas de proeminências ósseas na metade inferior do corpo, sendo que dois terços ao redor da pélvis (cerca de 60%

na região sacral e 15% em ísqüio e trocânter maior) e um terço nos membros inferiores, geralmente na região do calcanhar (GREY; HARDING; ENOCH, 2006).

O Painel Nacional Consultivo para Úlcera por Pressão (*National Pressure Ulcer Advisory Panel*, NPUAP)(EDSBERG et al., 2016), desenvolveu uma padronização da classificação de úlceras por pressão quanto à profundidade em relação à extensão da parede tissular envolvida (epiderme, derme, subcutâneo e tecidos mais profundos, como músculos, tendões, ossos e outros), sendo definidos em quatro estágios, ilustrados pela Figura 4.

Figura 4 – Estágios da úlcera por pressão.



Fonte: Edsberg et al. (2016).

- a) Estágio I: ocorre comprometimento da epiderme e a pele se encontra íntegra, mas apresenta sinais de hiperemia, descoloração, endurecida ou amolecida.
- b) Estágio II: pele com perda parcial da espessura da derme e se apresenta como uma úlcera superficial aberta, com leito rosado e sem esfacelo. Pode também apresentar-se como uma bolha, intacta ou rompida.
- c) Estágio III: pele com perda total da espessura da derme, epiderme, hipoderme e com a gordura subcutânea visível, mas o tendão, osso ou músculo não estão expostos. Essas lesões podem apresentar esfacelo, descolamentos e túneis. A profundidade da perda tissular varia conforme a localização anatômica.
- d) Estágio IV: pele com perda total da espessura da derme, epiderme, hipoderme e com osso, tendão ou músculo expostos. Essas lesões frequentemente apresentam descolamentos e túneis. A profundidade da perda tissular varia conforme a localização anatômica

Durante a cicatrização, o leito da úlcera pode apresentar uma variedade de cores que geralmente consistem da mistura dos tecidos de granulação (vermelho ou rosa escuro), esfacelo (amarelo, cinza ou esverdeado) e escara (marrom ou preto). O tecido de granulação

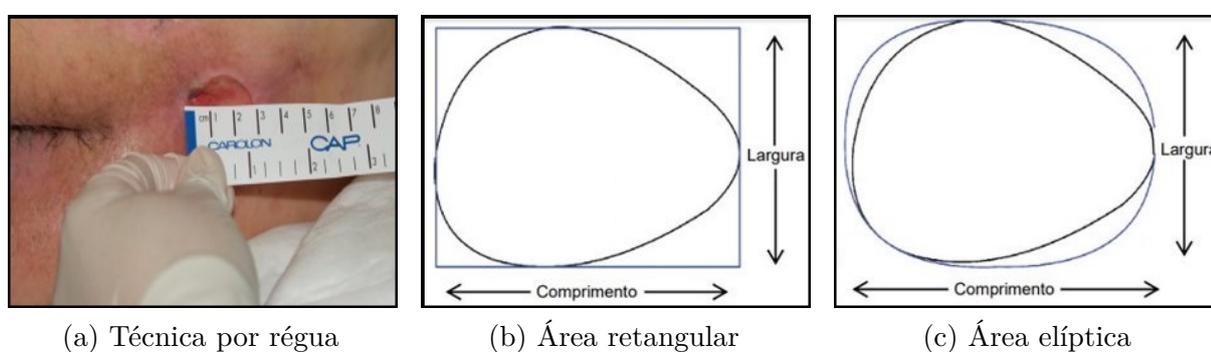
representa a formação de um tecido novo. Enquanto que o esfacelo demonstra a degradação celular. A escara representa o tecido morto e desidratado. O tecido de epitelização, que representa a cicatrização saudável que migra a partir da periferia para o centro da úlcera, tem aspecto róseo. Devido a complexidade, a cicatrização das lesões podem ser mais bem acompanhadas e descritas usando escalas de monitoramento (EDSBERG et al., 2016).

3.3 Técnicas Tradicionais de Mensuração

A mensuração de úlceras por pressão permite acompanhar a evolução do processo de cicatrização. A redução da área de uma úlcera é um dos indicadores mais importantes da cicatrização (GETHIN, 2006). Técnicas tradicionais de mensuração envolvem a utilização de réguas e decalques.

A Figura 5 demonstra as formas de se realizar a mensuração da área por meio de réguas (a). A forma de medição em (b) é utilizada em úlceras com formatos regulares, a área é obtida através da multiplicação das medidas de maior comprimento e largura. A forma de medição em (c) é utilizada para conseguir uma maior aproximação do formato da úlcera, baseando-se na geometria de uma elipse, é feita a multiplicação da área do retângulo obtida em (b) por $\pi/4$ (AHN et al., 2008).

Figura 5 – Técnica de mensuração por réguas.



Fonte: Adaptada de Ahn et al. (2008).

Outra forma de avaliação da área é por meio de utilização de decalque, ilustrado na Figura 6. O decalque consiste em traçar o formato da úlcera em material transparente. O material mais utilizado é o papel de acetato. Após o traçado, coloca-se o decalque sobre um papel quadriculado e conta-se o número de unidades de áreas inteiras.

A utilização dessas técnicas exigem contato direto com a úlcera, podendo causar infecções, desconforto ou piorar a condição clínica do paciente. Além disso, elas geralmente são imprecisas, subjetivas e sofrem com a falta padronização entre os profissionais da saúde (KEAST et al., 2004).

Figura 6 – Técnica de mensuração por decalques.



Fonte: Ahn et al. (2008).

4 DESCRIÇÃO E SEGMENTAÇÃO DE ÚLCERAS

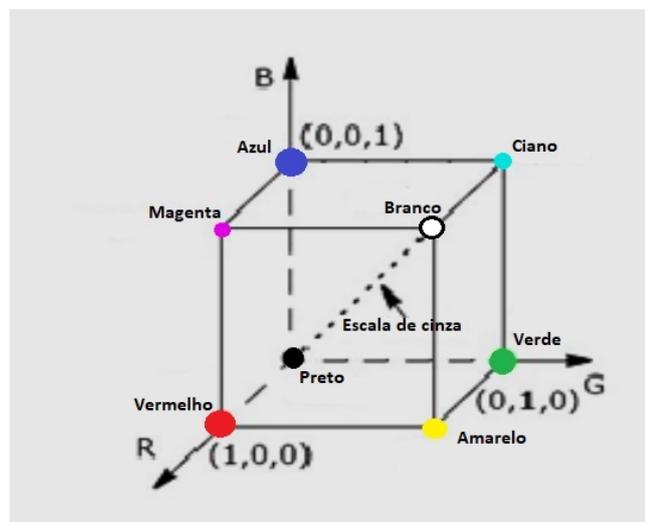
4.1 Espaço de Cores

Espaço de cores é um método pelo qual podemos especificar, criar e visualizar as cores definindo-as por seus atributos de brilho, tonalidade e cromática por meio de um sistema gráfico de coordenadas. Existem diversos espaços de cores padronizados pela CIE (Commission Internationale de l'Éclairage - Comissão Internacional de Iluminação) para especificação de cores, cujo as vantagens ou desvantagens estão vinculados ao tipo de aplicação (GONZALEZ; WOODS, 2006). Neste trabalho são utilizados os espaços de cores RGB (*Red, Green, Blue*), $L^*a^*b^*$ (*Lightness, green-red and blue-yellow color components*), Luv , HSV (Hue, Saturation and Value) e $NRGB$ (*Normalized Red, Green, Blue*).

4.1.1 Espaço de Cores RGB

O espaço de cores RGB é o modelo mais amplamente utilizado no processamento de imagens digitais. Nesse modelo, cada cor aparece em seus componentes espectrais primários de vermelho (R), verde (G) e azul (B). Ele se baseia em um sistema de coordenadas cartesianas tridimensionais, variando os valores de 0 a 1. O subespaço de cores de interesse pode ser representado por um cubo, ilustrado na Figura 7, no qual as diferentes cores são pontos no cubo ou dentro dele e são definidas por vetores que se estendem a partir da origem. Os valores RGB primários estão em três vértices; as cores secundárias ciano, magenta e amarelo estão em outros três vértices; o preto está na origem; e o branco está no vértice mais distante da origem. A escala de cinza (pontos de valores RGB iguais) estende-se do preto até o branco ao longo da reta que une dois pontos.

Figura 7 – Espaço de cores RGB.



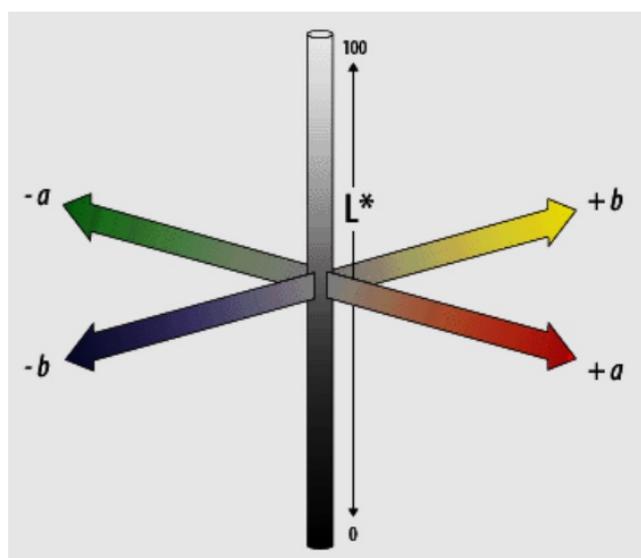
Fonte: Adaptada de Ibraheem et al. (2012).

4.1.2 Espaço de Cores $L^*a^*b^*$

O espaço de cores $L^*a^*b^*$ é um modelo de cor uniforme que exhibe as cores perceptíveis pelo olho humano. O $L^*a^*b^*$ é um sistema de cores que determina a cor dependendo da sua posição em um espaço de cores 3D, conforme ilustrado na Figura 8, sendo composto pela componente de luminância L^* e pelas componentes de cromaticidade a^* e b^* (IBRAHEEM et al., 2012).

A componente L^* indica como a intensidade luminosa é percebida no objeto, variando de 0 (preta) a 100 (branca). No componente a^* os valores positivos indicam vermelho, enquanto que valores negativos indicam verde. No componente b^* os valores positivos se referem ao amarelo, enquanto que valores negativos se referem ao azul.

Figura 8 – Espaço de cores $L^*a^*b^*$.

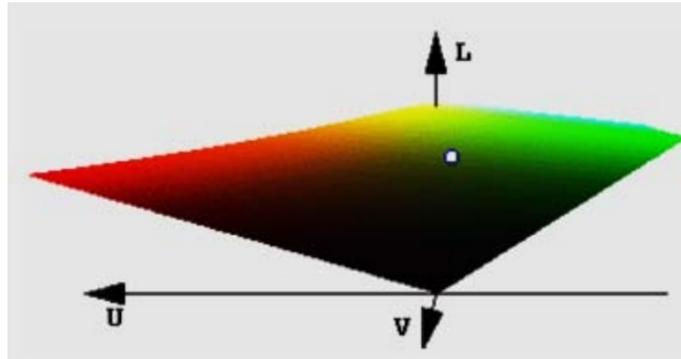


Fonte: Adaptada de Ibraheem et al. (2012).

4.1.3 Espaço de Cores Luv

O espaço de cores Luv é similar ao espaço de cores $L^*a^*b^*$. As diferenças entre eles estão no modelo matemático e no grau de separação da informação de luminância para com os componentes de cor, com o $L^*a^*b^*$ sendo melhor nesse quesito (GONZALEZ; WOODS, 2006). Assim como no $L^*a^*b^*$, o Luv é um modelo perceptualmente uniforme que exhibe as cores perceptíveis pelo olho humano. A componente L representa a luminância e as componentes u e v a cromaticidade. As cores nesse modelo podem ser obtidas a partir do deslocamento das componentes no espaço ilustrado na Figura 9.

Figura 9 – Espaço de cores Luv.



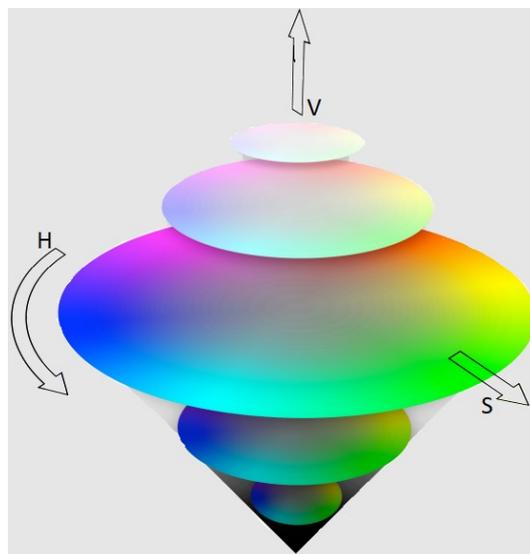
Fonte: Adaptada de Ibraheem et al. (2012).

4.1.4 Espaço de Cores HSV

O espaço de cores HSV (Hue, Saturation, value) é um modelo de cores baseado no sistema visual humano e construído a partir de uma forma geometria cilíndrica, como pode ser observado na Figura 10. Cada cor do modelo HSV é formada pelas componentes matiz (Hue), saturação (Saturation) e luminância (Value).

A matiz (Hue), abrange todo o espectro de cores que são dispostas circularmente de 0° a 360° , podendo ser normalizada para 0% a 100% que define a cor dominante (como vermelho, verde, roxo e amarelo) de uma área. A saturação (Saturation), que varia de 0% a 100%, mede o colorido de uma área em proporção ao seu brilho, ou seja, quanto menor seu valor mais acinzentada será uma determinada cor. A luminância (Value), com variação de 0% a 100%, onde 100% indica a máxima intensidade da cor.

Figura 10 – Espaço de cores HSV.



Fonte: Adaptada de Ibraheem et al. (2012).

4.1.5 Espaço de Cores NRGB

O NRGB é uma representação que é facilmente obtida a partir dos valores RGB por um procedimento simples de normalização Vezhnevets, Sazonov e Andreeva (2003):

$$r = \frac{R}{R + G + B} \quad g = \frac{G}{R + G + B} \quad b = \frac{B}{R + G + B} \quad (1)$$

onde R é a componente de cor vermelha, G a componente verde e B a componente azul. Uma propriedade notável dessa representação é que as componentes de cor são independentes da fonte de iluminação.

4.2 Superpixels

Superpixels é uma técnica de pré-processamento de imagens bastante utilizada no campo de visão computacional e aplicada a imagens de diversos tipos para a realização de segmentação, análise, localização, reconstrução 3-D e extração de características em objetos presentes na imagem (LI; CHEN, 2015). Esses métodos fornecem uma representação concisa da imagem ao agrupar os pixels em clusters de acordo com critérios de cor e/ou espaciais que determinam as bordas entre os objetos e o fundo presentes na imagem. A figura 11 mostra exemplos de segmentação em superpixels. Pesquisadores utilizaram alguns desses métodos para segmentar imagens de feridas crônicas, entre eles estão o J-SEG em (WANNOUS; TREUILLET; LUCAS, 2010), o *k-means* em (VEREDAS; MESA; MORENTE, 2015) e o SLIC em (WANG et al., 2016). Embora não exista um método de segmentação único que ofereça desempenho ideal em todos os tipos de imagens, métodos eficazes geralmente apresentam algumas propriedades comuns (ACHANTA et al., 2012), como preservação de informações de borda, eficiência computacional e exigência de poucos parâmetros. Com base nessas propriedades, três métodos lineares de segmentação baseados

Figura 11 – Segmentação com a estratégia por superpixels retratando diferentes quantidades de superpixels na imagem.



(a) 100 suuperpixels

(b) 200 superpixels

(c) 400 superpixels

Fonte: Elaborado pelo autor.

em superpixels foram considerados no método proposto: o SLIC (*Simple Linear Iterativa Clustering*) (ACHANTA et al., 2012), LSC (*Linear Spectral Clustering*) (LI; CHEN, 2015) e o SEEDS (*Superpixels Extracted via Energy-Driven Sampling*) (BERGH et al., 2015).

4.2.1 SLIC

O SLIC é um método de clusterização baseado no algoritmo *k-means*. O método combina as informações do espaço de cores $L^*a^*b^*$ e as posições espaciais (x,y) , criando um espaço de características na forma de 5-Dimensões. O espaço de características é utilizado para calcular a distância de similaridade entre os pixels e os clusters. Na etapa de atribuição, cada pixel é associado ao cluster que contém maior similaridade. As etapas de atribuição e mudança de pixels entre clusters são repetidas iterativamente até alcançar um critério de parada predefinido. Por fim, uma etapa de pós-processamento realiza a atribuição dos pixels não associados para um cluster espacialmente mais próximo.

4.2.2 LSC

O LSC é baseado no método *k-means* ponderado. O método utiliza funções *kernel* para mapear os pixels da imagem para pontos ponderados em um espaço de características na forma de 10-Dimensões. Em seguida, os pixels mapeados inicialmente são amostrados uniformemente pela imagem como sendo centros de clusters e funcionam como sementes de busca. Então, para cada pixel da imagem, é realizado o cálculo da média ponderada no espaço de características e o pixel é atribuído ao cluster com maior similaridade. Quando um pixel é atribuído em algum cluster, é realizado o recálculo da média ponderada do cluster e o seu centro é deslocado espacialmente para buscar novos pixels para serem atribuídos. Essas etapas são executadas iterativamente até os que centros dos clusters se estabilizem ou quando alcançam um critério de parada predefinido.

4.2.3 SEEDS

O SEEDS começa a partir de um particionamento uniforme inicial de clusters pela imagem. Em seguida, os clusters são refinados, trocando seus pixels entre clusters vizinhos a partir de uma função de energia. A função de energia é definida pela probabilidade de cor e pelos limites de bordas dos clusters. Então, aplica-se o algoritmo de otimização *Hill-Climbing* na função de energia para realizar a mudança dos pixels entre os clusters. O algoritmo atualiza os clusters de forma iterativa, propondo pequenas alterações locais a cada iteração. Como regra, se a função de energia aumentar com a atribuição do novo pixel, então o novo cluster é atualizado e gerado. O tempo de execução do método está relacionado ao número de iterações.

4.3 Extração de Descritores

Descritores de imagens são funções ou algoritmos utilizados para representar características, tais como cor, forma e textura (GONZALEZ; WOODS, 2006). O objetivo da extração de descritores é caracterizar os objetos, através de medidas, para serem utilizados em técnicas de classificação de imagens. Os descritores podem ser extraídos globalmente ou localmente. A extração global leva em consideração a distribuição de intensidade dos pixels de toda uma imagem. Enquanto que a local leva em consideração a distribuição de intensidade dos pixels em pequenas áreas da imagem. Neste trabalho, os descritores de cor e textura são extraídos de forma local, computados a partir de cada região segmentada pelas técnicas por superpixels descritas na Seção 4.2.

4.3.1 Descritores de Cor

A cor é uma das características mais importantes que possibilita o reconhecimento de imagens por seres humanos. A cor é uma propriedade que depende do reflexo da luz no olho e do processamento dessa informação no cérebro. Ela é uma dimensão importante da percepção visual humana que permite a discriminação e o reconhecimento da informação visual (GONZALEZ; WOODS, 2006). Os descritores de cores são relativamente fáceis de extrair, nos quais são construídos histogramas das cores avaliando-os de forma estatística.

Um histograma representa a distribuição de cores em uma imagem, em que cada compartimento do histograma corresponde a uma cor no espaço de cores quantizado. O histograma de uma imagem digital com níveis de intensidade no intervalo $[0, L - 1]$ é definido por Gonzalez e Woods (2006) como uma função discreta:

$$h(r_k) = n_k, \quad (2)$$

onde r_k é o k -ésimo valor de intensidade e n_k é a quantidade de pixels com intensidade r_k .

Os descritores de cores são calculados a partir do histograma de cada superpixel formado nas imagens. Os descritores estatísticos de média (μ), variância (σ^2) e assimetria (θ) foram considerados neste trabalho e são descritos a seguir.

$$\mu = \frac{1}{N_i} \sum_{k=0}^{L-1} r_{ki} \cdot n_{ki}, \quad (3)$$

$$\sigma^2 = \frac{1}{N_i} \sum_{k=0}^{L-1} (r_{ki} - \mu_i)^2 \cdot n_{ki}, \quad (4)$$

$$\theta = \frac{1}{\sigma_i^3} \sum_{k=0}^{L-1} \frac{r_{ki} - \mu_i}{N_i}, \quad (5)$$

onde N_i é representa a quantidade de pixels pertencentes ao superpixel i , r_{ki} é o k -ésimo valor de intensidade do pixel pertencente ao superpixel i , n_{ki} é a quantidade de pixels com

intensidade r_{ki} dentro do superpixel i e σ é o valor de desvio padrão das intensidades no superpixel. Também é considerado os valores de frequência e intensidade dos dois picos mais altos nos histogramas após aplicar o filtro da média móvel.

4.3.2 Descritores de Textura

A textura é uma característica que captura descrições de regiões. Os descritores de textura caracterizam a composição do objeto através de características como suavidade, rugosidade e regularidade. As principais abordagens para representação de texturas em imagens são a estatística, a estrutural e a espectral (GONZALEZ; WOODS, 2006). Neste trabalho, foram utilizados três métodos diferentes para realizar a extração dos descritores de textura pela abordagem estatística e que serão descritos a seguir.

4.3.2.1 Haralick

No trabalho de Haralick (1979) foram propostos 14 descritores de textura calculados a partir da matriz de co-ocorrência de tons de cinza GLCM (*Gray-Level Co-occurrence Matrix*). Sendo $C_{\Delta_x, \Delta_y}(i, j)$ a GLCM de uma imagem monocromática I na forma:

$$C_{\Delta_x, \Delta_y}(i, j) = \sum_{p=1}^n \sum_{q=1}^m \begin{cases} 1, & \text{se } I(p, q) = i \text{ e } I(p + \Delta_x, q + \Delta_y) = j \\ 0, & \text{senão,} \end{cases} \quad (6)$$

onde Δ_x e Δ_y são definidos como:

$$\Delta_x = D \cdot \cos(\theta) \quad (7)$$

$$\Delta_y = D \cdot \sin(\theta) \quad (8)$$

onde θ e D , utilizados na construção da matriz, são o deslocamento da direção e a distância do pixel central para com seus vizinhos, respectivamente. A seguir destacam-se alguns descritores de Haralick, baseados na matriz de co-ocorrência C_{Δ_x, Δ_y} definida na equação 6 para cada superpixel formado nas imagens.

- a) O contraste quantifica a variação de tons de cinza da textura, representando o contraste entre um pixel e sua vizinhança. Sendo assim, um superpixel constante e com energia 1 possui o contraste igual a 0:

$$\text{Contraste} = \sum_{i,j=0}^{N-1} P_{i,j} \cdot (i - j)^2 \quad (9)$$

- b) A homogeneidade caracteriza a similaridade dos pixels:

$$\text{Homogeneidade} = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad (10)$$

c) A entropia caracteriza a desorganização do superpixel ou a sua aleatoriedade:

$$Entropia = - \sum_{i,j=0}^{N-1} P_{i,j} \cdot \log_2 P_{i,j} \quad (11)$$

d) A energia representa a uniformidade. Assim, quanto mais uniforme for o superpixel, maior será a energia, tendo o valor máximo de 1 quando for constante:

$$Energia = \sqrt{\sum_{i,j=0}^{N-1} (P_{i,j})^2} \quad (12)$$

e) A correlação quantifica o quanto um pixel é correlacionado com a sua vizinhança:

$$Correlação = \sum_{i,j=0}^{N-1} P_{i,j} \cdot \left[\frac{(i - \mu_i) \cdot (j - \mu_j)}{\sqrt{(\sigma_i^2) \cdot (\sigma_j^2)}} \right] \quad (13)$$

Onde i representa a linha e j a coluna da matriz de co-ocorrência, N é o número de linhas ou colunas, $P_{i,j}$ é o valor de probabilidade na célula (i, j) , μ é o valor de média e σ é o valor de variância.

4.3.2.2 Local Binary Patterns Histograms (LBPH)

O LBPH é um descritor local de textura computado a partir de histogramas, método formulado por Ojala, Pietikainen e Maenpaa (2002). O LBPH é aplicado em imagens em escala de cinza, onde as informações de textura são extraídas através da análise entre pixels vizinhos. Os histogramas são computados da seguinte forma:

$$h_i = \sum_{k=1}^W \sum_{l=1}^W f_g(i, j) \cdot P(k, l) \quad (14)$$

onde W é o tamanho da vizinhança de pixels a serem considerados, h_i representa o intervalo do histograma a ser acrescido em uma unidade, $f_g(i, j)$ é a função degrau de Heaviside dada na forma:

$$F_g(i, j) = H[A(k, l) - g(i, j)] \quad (15)$$

onde

$$H[A(k, l) - g(i, j)] = \begin{cases} 0, & [A(k, l) - g(i, j)] < 0 \\ 1, & [A(k, l) - g(i, j)] \geq 0 \end{cases} \quad (16)$$

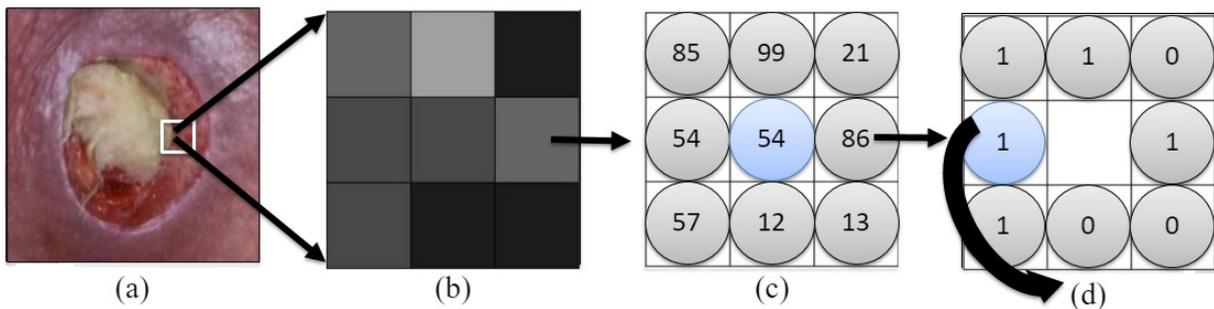
com $g(i, j)$ representando o pixel central e $A(k, l)$ a vizinhança ao redor de $g(i, j)$. Neste trabalho foi considerado uma vizinhança de tamanho 3 x 3 (vizinhança 8) como mostra a Figura 12 (c). Por fim, $P(k, l)$ é uma matriz de valores ponderados predefinidos para cada posição de pixel dentro da vizinhança 3 x 3, dada na forma:

$$P(k, l) = \begin{vmatrix} 1 & 2 & 4 \\ 128 & 0 & 8 \\ 64 & 32 & 16 \end{vmatrix}. \quad (17)$$

A Figura 12 resume o processo do método LBPH. Ao selecionar os pixels de uma vizinhança 3 x 3 qualquer, representada na Figura 12 (b), aplica-se a Regra 16 para criar uma matriz com valores binários, Figura 12 (d). Esses valores binários são utilizados para calcular o valor do intervalo a ser acrescido em uma unidade no histograma h_i . Esse valor é calculado simplesmente realizando o somatório da multiplicação entre os valores binários da Figura 12 (d) e a matriz ponderada $P(k, l)$, em suas respectivas posições, $h_i = 128 * 1 + 64 * 1 + \dots + 2 * 1 + 1 * 1 \rightarrow h_i = 203$. Outra forma de encontrar o intervalo h_i , é através do código binário da Figura 12 (d). Para isso, seleciona-se uma célula como sendo o bit mais significativo, realçada em azul na figura, e então o número binário é formado realizando a concatenação dos bits no sentido horário ou anti-horário. Neste caso, como indicado pela seta na Figura 12 (d), a construção do número foi realizada no sentido anti-horário, cujo o código binário gerado foi $h_i = 11001011$ ou em decimal $h_i = 203$.

Os descritores derivados dos histogramas LBPH de cada superpixel são os valores de média, variância, energia e entropia.

Figura 12 – Esquema de criação do LBPH. (a) Imagem original; (b) Seleção dos pixels na vizinhança 3 x 3; (c) Valores dos pixels em escala de cinza. Pixel central realçado em azul e sua vizinhança 8 realçada em cinza; (d) Número binário representando o intervalo do histograma a ser acrescido em uma unidade.



Fonte: Elaborado pelo autor.

4.3.2.3 Transformada Wavelet Discreta (DWT)

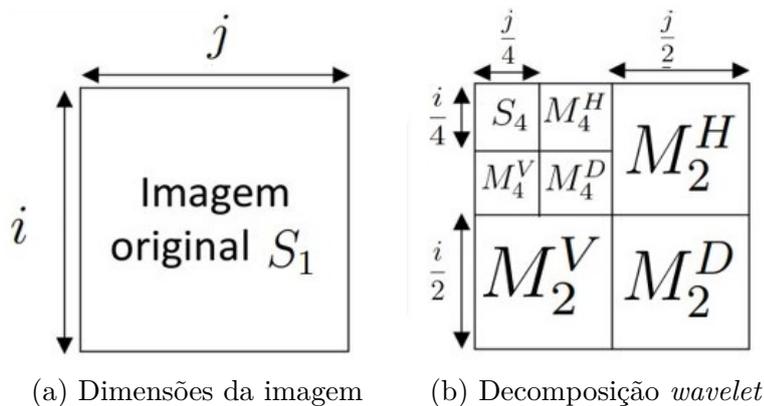
A transformada *wavelet* discreta (DWT) de um sinal $f(t)$ de uma dimensão é definida por Goswami e Chan (2011) da seguinte forma:

$$W_{\psi} f(k2^{-s}, 2^{-s}) = 2^{\frac{s}{2}} \sum_n f(n) \psi(2^s n - k). \quad (18)$$

A DWT para sinais de duas dimensões (exemplo das imagens digitais) é dada pela combinação de duas DWT de uma dimensão definida na Equação 18. Primeiro, realiza-se a DWT ao longo da direção horizontal (colunas) e depois na direção vertical (linhas). A Figura 13 resume a aplicação da DWT em uma imagem digital através da decomposição hierárquica piramidal (GOSWAMI; CHAN, 2011). A figura ilustra a imagem original S_1

de dimensões $i \times j$ pixels em (a) e sua decomposição *wavelet* piramidal em dois níveis em (b). Basicamente, a imagem S_1 passa através de filtros passa-baixas e passa-altas reduzindo suas dimensões espaciais pela metade. Assim, este processo irá decompor a imagem de entrada em uma série de sub-imagens em escalas diferentes. No primeiro nível de decomposição, uma imagem S_2 é obtida pelo filtro de passa-baixas, referida como imagem de baixa resolução. Nesse mesmo nível de decomposição, outras três imagens M_2^H , M_2^V e M_2^D , referidas como imagens de detalhes, são obtidas pelo filtro passa-altas, contendo detalhes nas orientações horizontal, vertical e diagonal, respectivamente. No segundo nível de decomposição, a sub-imagem S_2 é decomposta gerando outra imagem de baixa resolução S_4 e outras três imagens de detalhes M_4^H , M_4^V e M_4^D . O processo é repetido em n níveis de decomposição, sempre na imagem de baixa resolução, para formar um nível mais alto de decomposição *wavelet*. Em outras palavras, a DWT decompõe a imagem em uma estrutura de pirâmide de sub-imagens com várias resoluções correspondendo às diferentes escalas.

Figura 13 – Exemplo de estrutura piramidal *wavelet*. (a) Representação de uma imagem digital; (b) Estrutura piramidal do segundo nível de decomposição *wavelet*.



Fonte: Elaborado pelo autor.

As imagens de detalhes (M_X^H , M_X^V e M_X^D) obtidas pela aplicação da DWT podem ser usadas como fonte para extração de descritores de textura. Essas imagens contêm essencialmente informações de borda em uma direção específica (horizontal, vertical e diagonal) identificadas como coeficientes *wavelet* de maior valor de intensidade e utilizados para calcular os descritores de energia e entropia.

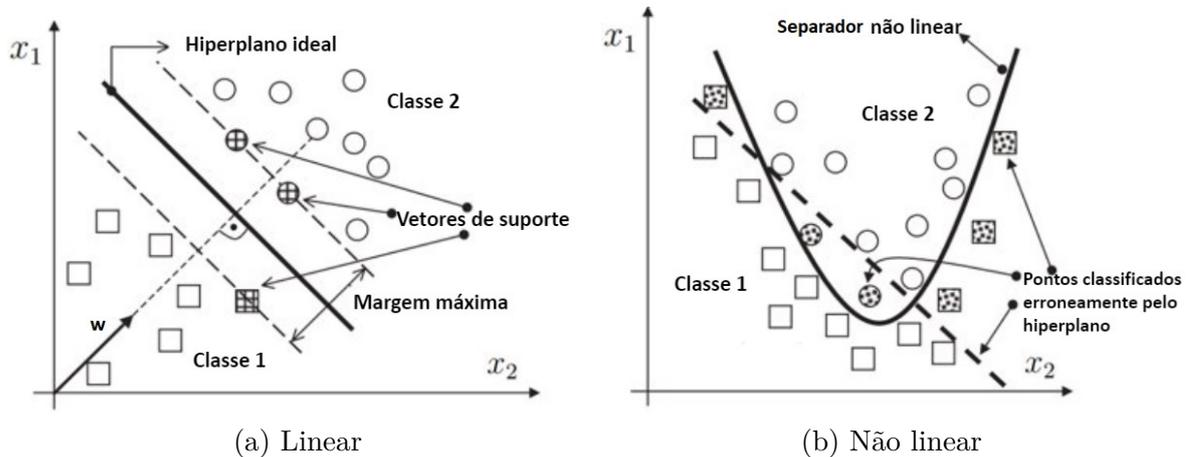
4.4 Máquinas de Vetores de Suporte (SVM)

As Máquinas de Vetores de Suporte (SVM) são um classificador baseado na Teoria de Aprendizagem Estatística proposta por Vapnik Vapnik (1995). O SVM é um método de aprendizagem de máquina supervisionado, que gera funções de mapeamento de entrada-

saída a partir de um conjunto de dados de treino previamente rotulados com as classes de domínio do problema e foi inicialmente proposto para classificações binárias (WANG, 2005).

O SVM para classificação binária pode ser definido da seguinte forma: Supondo duas classes, cada uma formada por um conjunto de pontos definidos por suas características, o SVM determina um hiperplano no espaço das características para separar o maior número de pontos da mesma classe de um lado do hiperplano e ao mesmo tempo maximizar a distância entre as classes para com o hiperplano. O hiperplano ideal será aquele que mantém uma margem máxima de ambas as classes analisadas. Os pontos mais próximos do hiperplano são conhecidos como vetores de suporte. A Figura 14 (a) exemplifica a distribuição de dados linearmente separáveis e a atuação do SVM em separá-los.

Figura 14 – Dados linearmente separáveis versus não linearmente separáveis.



Fonte: Adaptada de Wang (2005).

O modelo mais simples do SVM é aplicado em dados linearmente separáveis e consiste em encontrar a margem máxima entre as duas classes. Sendo assim, o hiperplano de separação pode ser definido como:

$$f(x) = w \cdot x + b \quad (19)$$

$$\text{onde} = \begin{cases} w \cdot x & \text{produto interno dos vetores } w \text{ e } x \\ \frac{b}{\|w\|} & \text{distância perpendicular entre o hiperplano e a origem} \\ w & \text{vetor normal perpendicular ao hiperplano} \end{cases}$$

A formulação do problema de otimização da margem máxima é definida como:

$$\min_{W,b,\xi} \frac{1}{2} W^T W + C \sum_{i=1}^n \xi_i \quad (20)$$

onde a variável C é utilizada para controlar o ajuste do tamanho do espaço e a adição da variável ξ para correção de pontos ruidosos.

Em grande parte dos casos, os conjuntos de dados não são linearmente separáveis, como ilustrado na Figura 14 (b). Conjuntos de dados não linearmente separáveis podem se tornar separáveis ao mapeá-los para um espaço dimensional maior. O mapeamento dos dados é dado através de uma função chamada de *kernel* e é o ponto-chave para uma classificação apropriada, podendo ser definida como:

$$K(X_i, X_j) \equiv \phi(X_i)^T \phi(X_j). \quad (21)$$

Segundo Wu e Wang (2009) os *kernels* mais utilizados são:

- a) Linear: $K(X_i, X_j) = \langle X_i, X_j \rangle$;
- b) Polinomial: $K(X_i, X_j) = (\gamma \langle X_i, X_j \rangle + r)^C$;
- c) Função de Base Radial (RBF): $K(X_i, X_j) = e^{-\gamma \|X_i - X_j\|^C}$, $\gamma > 0$;
- d) Sigmoide: $K(X_i, X_j) = \tanh \gamma \langle X_i, X_j \rangle + r$.

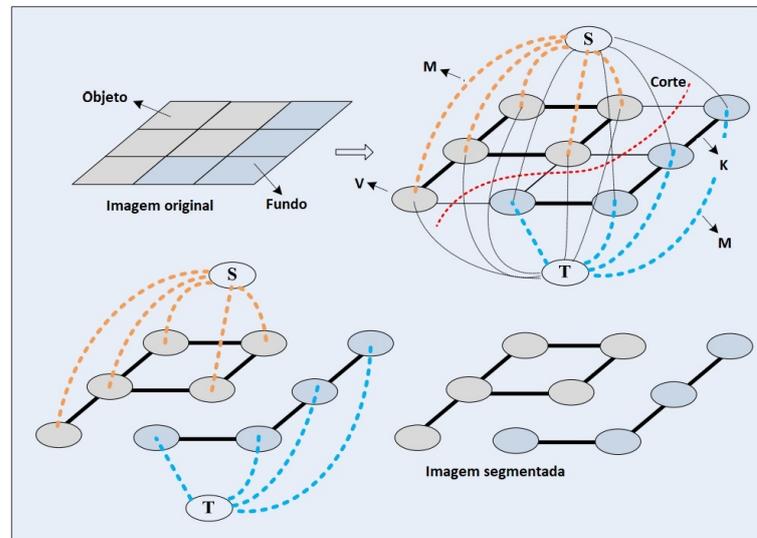
4.5 GrabCut

O GrabCut é um método de segmentação interativa proposto por Rother, Kolmogorov e Blake (2004). Ele é baseado em análise estatística e na teoria dos grafos (Graph-based image segmentation) que visa separar um objeto de interesse do restante da imagem. Para iniciar o processo em sua forma original, o usuário delimita o objeto a ser segmentado dentro de um retângulo. Em seguida, usando o Modelo Estocástico de Misturas Gaussianas (GMM), o método estima a distribuição de cores dos pixels do objeto e do plano de fundo, rotulando-os como provavelmente objeto ou provavelmente fundo. O modelo estocástico é usado para a construção do grafo \mathbf{G} :

$$\mathbf{G} = \langle \mathbf{V}, \mathbf{K} \rangle, \quad (22)$$

onde \mathbf{V} são vértices, no contexto de imagens \mathbf{V} são os pixels, e \mathbf{K} são as arestas que conectam os vértices na rede. Em adição ao grafo, são criados os nodos especiais \mathbf{S} (fonte) e \mathbf{T} (destino) que se conectam a todos os vértices por meio de arestas especiais \mathbf{M} . Este tipo de grafo é conhecido como $\mathbf{S-T}$, onde o nodo \mathbf{S} representa o objeto enquanto que o nodo \mathbf{T} representa o fundo (YI; MOON, 2012). A Figura 15 mostra a conectividade do grafo descrito. No grafo, todas as arestas recebem pesos, também chamados de custo, definidos a partir de informações por similaridade entre os pixels (arestas \mathbf{K}) ou por região em que os pixels estão inseridos (arestas \mathbf{M}). Por fim, os algoritmos iterativos de corte-mínimo e fluxo-máximo são utilizados para segmentar o grafo. Estes algoritmos determinam o custo mínimo do corte que irá separar os nodos \mathbf{S} e \mathbf{T} em objeto e fundo, respectivamente.

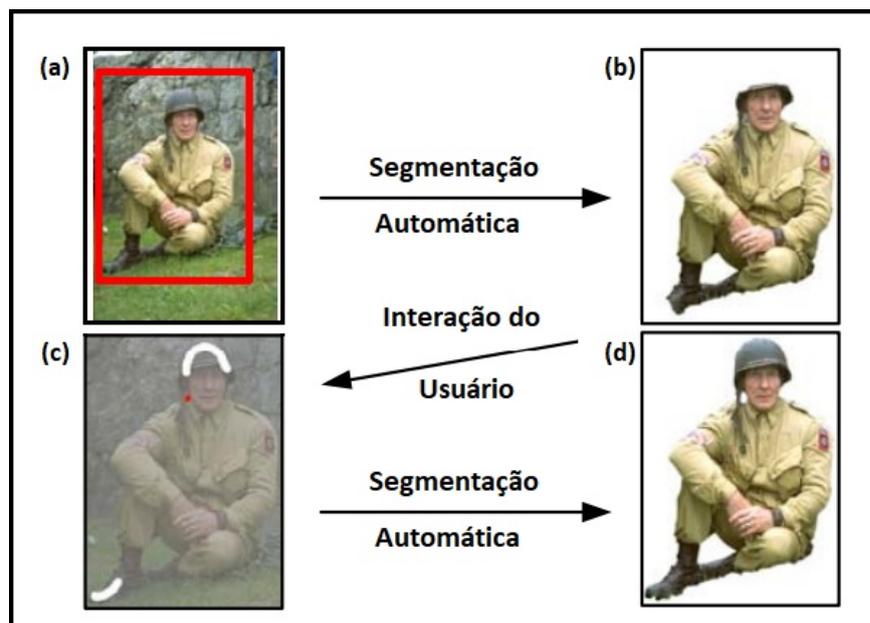
Figura 15 – Ilustração do grafo S-T e seu corte mínimo.



Fonte: Adaptada de Yi e Moon (2012).

O método GrabCut é interativo com o usuário. Quando o método não alcança uma segmentação satisfatória através da delimitação pelo retângulo, o usuário pode apontar as regiões que foram segmentadas incorretamente para que o método possa melhorar os resultados, como ilustra a Figura 16.

Figura 16 – Segmentação com o método GrabCut. (a) Imagem original com o objeto de interesse delimitado por um retângulo vermelho. (b) Segmentação inicial realizada pelo GrabCut. (c) Interação do usuário com apontamento das regiões segmentadas erroneamente. Traço em branco indica inclusão e traço vermelho indica exclusão das regiões. (d) Segmentação final.

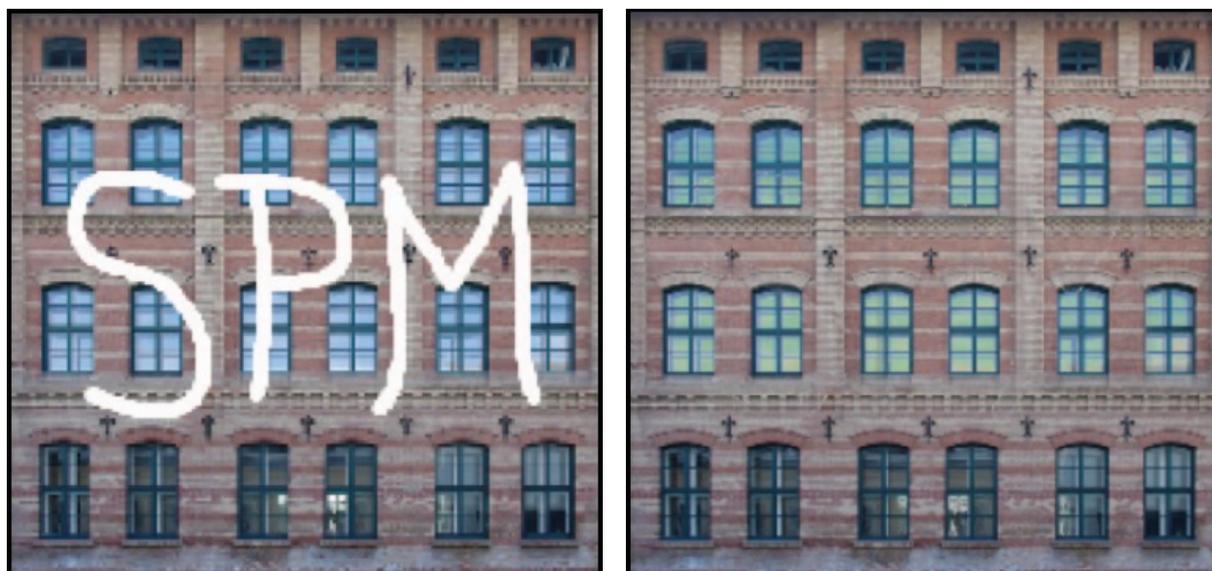


Fonte: Adaptada de Rother, Kolmogorov e Blake (2004).

4.6 Inpainting

Os métodos *inpainting* são uma classe de algoritmos em visão computacional em que o objetivo é restaurar regiões danificadas em imagens e vídeos, como manchas, arranhões, texto e logotipos sobrepostos. Esses métodos são guiados pela suposição de que os pixels nas partes conhecidas e danificadas da imagem compartilham as mesmas propriedades estatísticas ou estruturas geométricas (GUILLEMOT; MEUR, 2013). Essa suposição se traduz em diferentes prioridades locais ou globais, com o objetivo de ter uma imagem restaurada o mais fisicamente plausível e visualmente agradável. A maioria dos métodos *inpainting* funciona da seguinte maneira. Primeiro, as regiões da imagem a serem restauradas são selecionadas, geralmente manualmente. Em seguida, a informação de cor nos limites ao redor das áreas danificadas é propagada para dentro da região danificada, ou seja, as informações conhecidas da imagem são usadas para preencher as áreas danificadas. A fim de produzir uma restauração perceptualmente plausível, um método *inpainting* deve tentar continuar as linhas de igual valor de cinza tão suavemente quanto possível dentro da região a ser reconstruída. A Figura 17 mostra um exemplo de restauração de uma imagem utilizando o método *inpainting* de Telea (2004).

Figura 17 – Exemplo de restauração de uma imagem utilizando o método *inpainting* de Telea (2004). (a) Imagem danificada por traços brancos sobrepostos; (b) Imagem restaurada pelo método.



(a) Imagem com traços brancos sobrepostos

(b) Imagem restaurada

Fonte: Guillemot e Meur (2013)

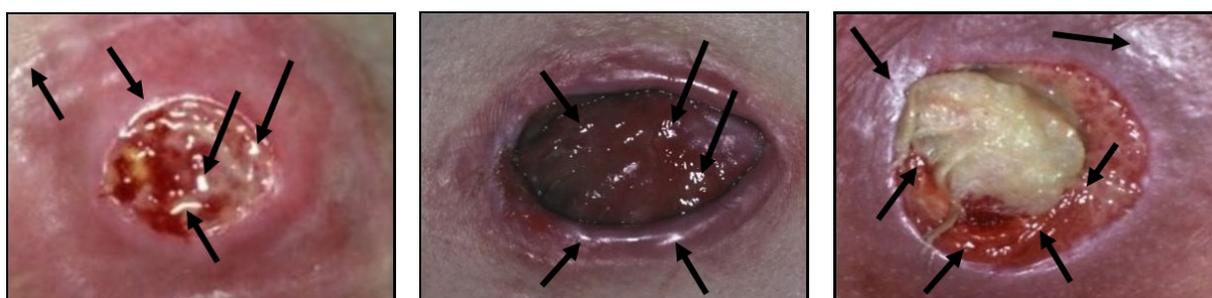
5 MATERIAIS E MÉTODOS

5.1 Conjunto de Dados

O conjunto de dados utilizado no estudo é composto por 105 imagens de úlceras por pressão com resolução de 410 x 560 pixels, retiradas do MEDETEC, banco de dados público de imagens de feridas (MEDETEC, 2007). Alguns critérios foram adotados para a seleção das imagens, excluindo-se as que apresentam úlceras de pequeno tamanho, aquelas que não possuem pele íntegra ao redor da lesão, aquelas que possuem objetos que interferem diretamente na identificação total da úlcera, como hastes, dedos ou dispositivos médicos e aquelas com apenas pequenas escoriações. Além disso, as imagens foram recortadas, retratando, quando possível, somente regiões de pele e de úlcera, evitando interferências de fundo do ambiente hospitalar e redimensionadas para 240 x 300 pixels utilizando a interpolação bicúbica (GONZALEZ; WOODS, 2006) a fim de manter suas dimensões padronizadas.

Como o banco de dados MEDETEC não foi projetado para fins de avaliações por métodos computacionais, existem alguns artefatos que dificultam o processamento dessas imagens. O principal artefato encontrado foi a luz refletida, ilustrada na Figura 18. Reflexos de luz possuem pixels de alta intensidade que distorcem a cor dos tecidos e estão presentes tanto na úlcera quanto na pele, afetando diretamente o processo de segmentação e classificação pelos métodos computacionais.

Figura 18 – Exemplo de reflexos de luz nas imagens de úlcera. Setas de cor preta apontam regiões de úlcera e de pele com reflexos de luz.



Fonte: Adaptada de Medetec (2007)

5.2 Pré-processamento dos Dados

Antes de submeter as imagens às etapas de segmentação em superpixels, extração de características, normalização dos descritores, classificação e segmentação com GrabCut é necessário identificar e remover regiões de reflexo de luz. Essas regiões possuem cor branca brilhante que são caracterizadas por alta intensidade, saturação e contraste. Para remover

esses artefatos, é realizada uma etapa de pré-processamento baseada no procedimento apresentado por Kudva, Prasad e Guruvare (2017). As imagens RGB são primeiramente convertidas para os espaços de cores HSV e $L^*a^*b^*$, e as componentes de Saturação (S), Verde (G) e Luminosidade (L) são usadas para calcular uma imagem de características F da seguinte forma:

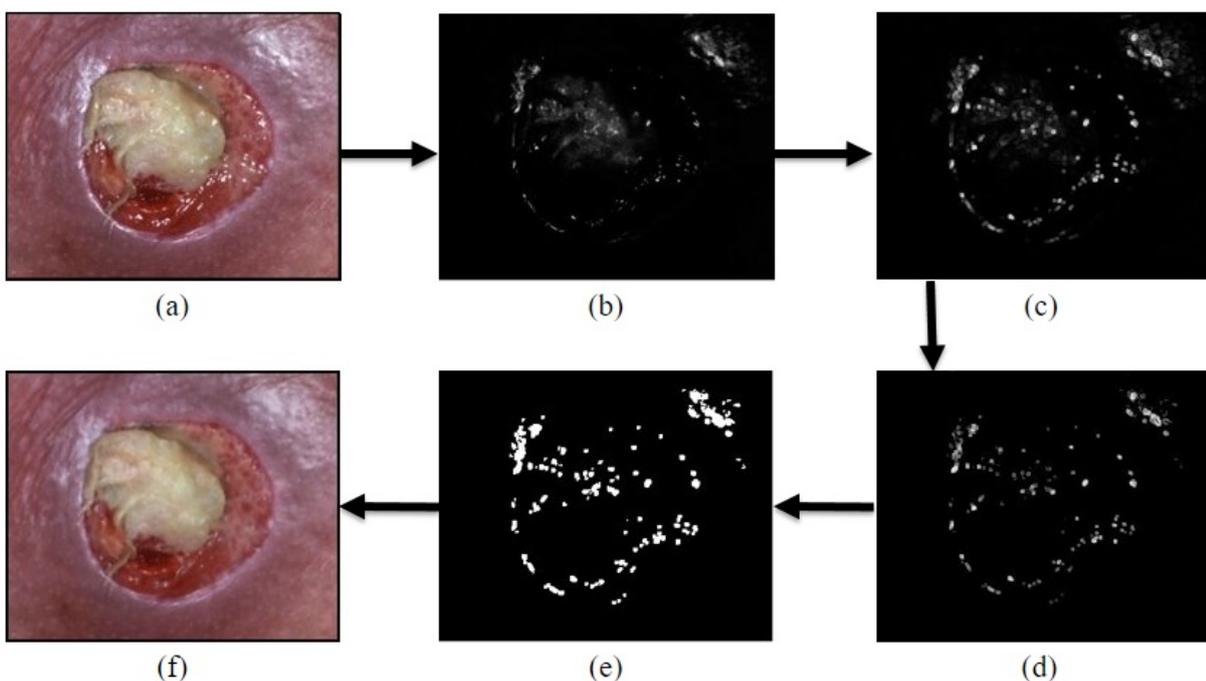
$$F = ((1 - S) \cdot G \cdot L)^3 \quad (23)$$

A imagem de características F é filtrada pelo filtro de desvio padrão de tamanho 3 (vizinhança oito), da seguinte forma:

$$\sigma = \sqrt{\frac{\sum_{i,j=0}^{N-1} (f_{(i,j)} - \bar{f})^2}{m \cdot n - 1}}, \quad (24)$$

onde σ é o valor de desvio padrão, i representa a linha e j a coluna da imagem F , N é o número de linhas ou colunas, $f_{(i,j)}$ é o valor da intensidade do pixel na posição (i, j) , \bar{f} é a intensidade média dos pixels na vizinhança oito, m é o número de linhas e n o número de colunas do filtro de desvio padrão. Após a aplicação do filtro, a imagem passa por um processo de limiarização. Ao contrário do trabalho de Kudva, Prasad e Guruvare

Figura 19 – Processo de remoção e reconstrução das regiões de reflexos de luz. (a) Imagem original; (b) Imagem de características; (c) Aplicação do filtro de desvio padrão; (d) Imagem limiarizada; (e) Imagem binária identificando as regiões de reflexo de luz em cor branca; (f) Resultado da imagem após aplicação do método *inpainting* e do filtro de média.



Fonte: Elaborado pelo autor.

(2017) que utilizou um limiar de $0,9v$, sendo v o maior valor de intensidade encontrado na imagem de características F , no presente trabalho foi escolhido um limiar de valor $0,8v$ devido à baixa resolução das imagens na base de dados MEDETEC. Em seguida, a imagem limiarizada é preenchida e dilatada utilizando um elemento estruturante na forma de disco de tamanho 2, resultando em uma imagem binária que identifica as regiões de reflexo de luz.

Por fim, a remoção e reconstrução das regiões de reflexo de luz é realizada através do método *inpainting* (TELEA, 2004). O método recebe como parâmetros a imagem binária, que o informa das regiões a serem reconstruídas, e o tamanho do raio de vizinhos a serem considerados para a reconstrução, foi utilizado raio de tamanho $r = 3$. Basicamente, o algoritmo preenche as regiões de reflexo de luz com pixels vizinhos a ela, recuperando as cores que foram escondidas pelo reflexo. Após a reconstrução, aplica-se o filtro de média de tamanho 3 para suavizar e remover ruídos, a Figura 19 sumariza todo o pré-processamento.

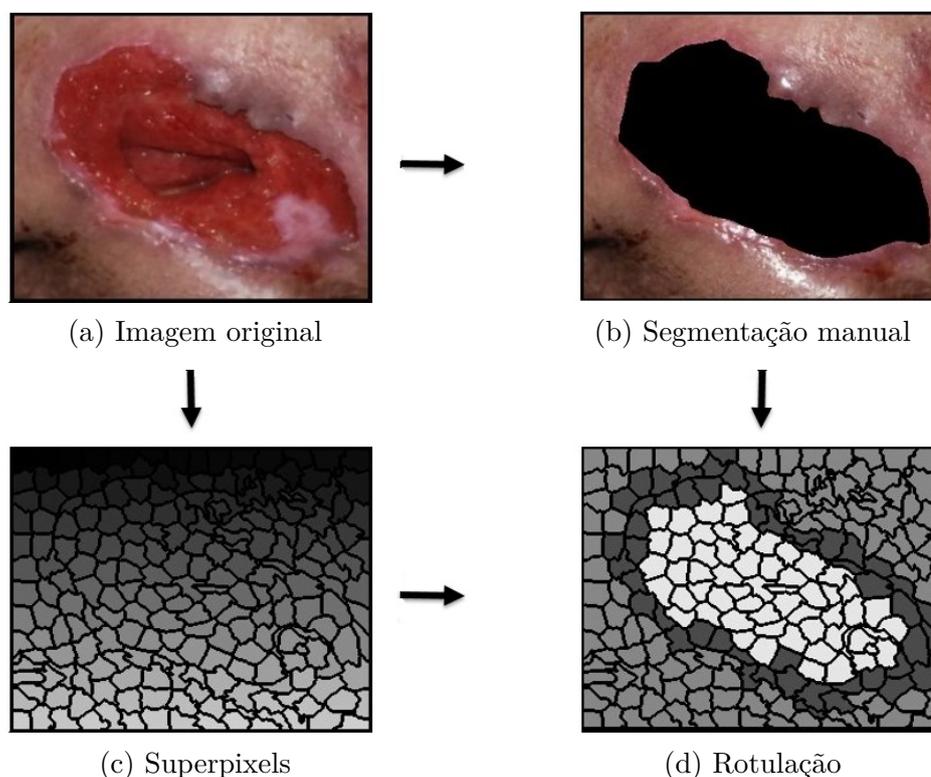
5.3 Segmentação em Superpixels

A segmentação em superpixels tem como principal objetivo extrair os descritores locais de cor e textura sendo, portanto, primeiramente necessário segmentar as imagens em pequenas regiões. O conjunto de 105 imagens foi dividido aleatoriamente em conjuntos de treinamento, validação e teste. O conjunto usado para treinamento e validação, composto por 84 imagens (80% do conjunto), foi primeiramente convertido em mapas de superpixel com base nos métodos SLIC, LSC e SEEDS. Os superpixels foram rotulados em úlcera e não úlcera de acordo com a segmentação manual realizada por um enfermeiro utilizando o programa ImageJ® (SCHNEIDER; RASBAND; ELICEIRI, 2012), onde através do método *Polygon selections* as bordas das lesões foram traçadas com o *mouse*. Os superpixels que se encontram entre as regiões de úlcera e pele são descartados, pois podem estar parcialmente em ambas, interferindo no processo de treinamento do classificador SVM. Além disso, foram criadas quantidades balanceadas com rótulos de úlcera e não úlcera. No conjunto de imagens segmentadas pelo SLIC foram formados 7900 superpixels, sendo 3950 rótulos de úlcera e 3950 de não úlcera. Nos conjuntos SEEDS e LSC foram 7324 e 7736 superpixels, respectivamente. A Figura 20 exemplifica o processo de rotulação dos superpixels. A úlcera (a) passa pelos processos de segmentação manual (b) e pela segmentação por superpixels (c). Então, com as regiões identificadas em (b), os superpixels são rotulados em (c). Em (d) é ilustrado os rótulos de úlcera (cor branca), não úlcera (cor cinza claro) e os superpixels que são excluídos (cor cinza escuro) do conjunto.

5.4 Extração dos Descritores de Cor e Textura

Cada superpixel do conjunto de treino é um par composto por um vetor de descritores de características e um rótulo que representa a sua classe como sendo úlcera ou

Figura 20 – Processo de rotulação dos superpixels. (a) Imagem original; (b) Segmentação manual; (c) Segmentação por superpixels; (d) Rotulação dos superpixels. Cor cinza claro representa regiões de não úlcera, branco as regiões de úlcera e cinza escuro os superpixels compostos por ambos os tecidos que foram excluídos.



Fonte: Elaborado pelo autor.

não úlcera. A extração dos descritores é realizada por diferentes técnicas. O método proposto neste trabalho inclui extração de cor e textura realizadas em cada superpixel formado pelos métodos SLIC, LSC e SEEDS. Em termos de selecionar descritores apropriados para a tarefa de classificação de úlceras, foram combinados diferentes descritores de cor e textura estudados e aplicados nos trabalhos de (WANNOUS; TREUILLET; LUCAS, 2010), (VEREDAS; MESA; MORENTE, 2009), (PEREIRA et al., 2013) e (WANG et al., 2016). A seguir serão descritos as formas pelas quais foram realizadas as extrações dos descritores de características utilizados neste trabalho, formando um vetor de atributos com 186 posições.

A extração dos descritores de características de cor é baseada na análise estatística de histogramas dos componentes de cor R , G , B , L^* , a^* , b^* , L , u , v e Normalizados R , G e B . Em cada histograma, os descritores calculados são os valores de média (μ), variância (σ^2), assimetria (θ) e os valores de frequência e intensidade dos dois picos mais altos nos histogramas após aplicar o filtro da média móvel. Além desses descritores, também foi utilizado a centroide de cada superpixel em cada um dos espaços de cores como sendo

descriptor de cor dominante. Deste modo, obtém-se um vetor com 96 posições representando os atributos de cores.

Para a extração dos descritores de características de textura foram utilizados os métodos de Haralick, LBPH e DWT, cada processo é descrito a seguir.

Os descritores de Haralick foram calculados para cada superpixel nas componentes de cor R , G , B , a^* , b^* , u e v . Os descritores de contraste, homogeneidade, entropia, energia e correlação foram calculados através da matriz de co-ocorrência média computada a partir das matrizes de co-ocorrência da Equação 6 nos deslocamentos de direção θ de 0° , 45° , 90° e 135° com distância D de 1 pixel. Além disso, esses cinco descritores também foram computados na matriz de co-ocorrência de cor, método proposto em (ARVIS et al., 2004), combinando as componentes RG , RB , GB , a^*b^* e uv . Esse método é uma derivação de Haralick, ele leva em consideração a correlação existente entre as componentes de cor. Deste modo, obtém-se um vetor de descritores com 60 posições de atributos de textura calculados pelos métodos de Haralick e de sua derivação.

Os descritores LBPH foram computados a partir dos histogramas formados pela Equação 14 em cada superpixel de cada componente de cor do espaço de cores RGB. Os descritores derivados dos histogramas LBPH são os valores de média (μ), variância (σ^2), energia e entropia. Deste modo, obtém-se um vetor de descritores LBPH com 12 posições.

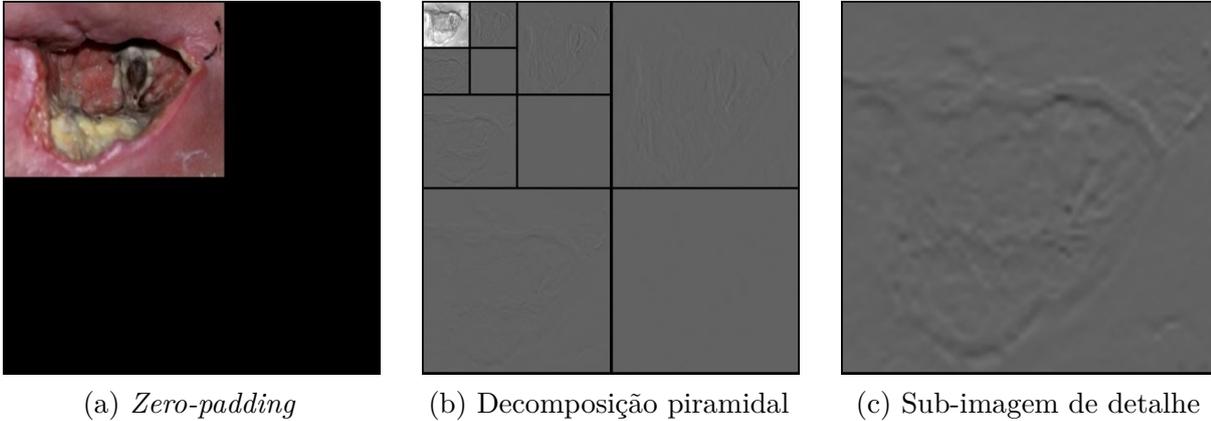
Por fim, os descritores derivados da DWT. Para realizar a extração desses descritores, as imagens do conjunto são estendidas pelo processo de *zero-padding* para torná-las quadráticas de proporções 512 x 512 pixels. Esse processo é necessário para realizar a aplicação da DWT (Equação 18) nas direções horizontal e vertical (GOSWAMI; CHAN, 2011). Então, após a aplicação da DWT nas imagens quadráticas, o *zero-padding* é removido para recuperar as dimensões originais da imagem e são consideradas as três sub-imagens de detalhes nas orientações horizontal, vertical e diagonal (M_8^H , M_8^V e M_8^D) do terceiro nível de decomposição *wavelet* para cada componente R, G, e B do espaço de cores RGB, totalizando 9 sub-imagens. Cada uma dessas sub-imagens são amostradas para o mesmo tamanho da imagem original de 240 x 300 pixels utilizando a interpolação bicúbica (GONZALEZ; WOODS, 2006). Esse procedimento é necessário para recuperar as coordenadas espaciais de cada pixel dentro do superpixel analisado. A Figura 21 mostra o processo realizado. Para cada sub-imagem do terceiro nível, o descriptor de energia é extraído de cada superpixel. Para a extração do descriptor de entropia, antes é necessário normalizar o valor de intensidade para evitar valores negativos dos coeficientes *wavelet* das sub-imagens, procedimento realizado na forma:

$$M_8^X = \sum_{i,j=0}^N P(i,j) + |f|, \quad X \in H, V, D, \quad (25)$$

onde i representa a linha e j a coluna na imagem, N é o número de linhas ou colunas, $P_i(i,j)$ representa o pixel e $|f|$ é o módulo do menor valor de intensidade na sub-imagem

de detalhe X . Deste modo, obtém-se um vetor de descritores com 18 posições pela DWT.

Figura 21 – Esquema de aplicação da TWD em uma imagem digital. (a) Imagem com *zero-padding*. (b) Estrutura piramidal de decomposição *wavelet*. (c) Sub-imagem de detalhe de decomposição *wavelet* amostrada para o tamanho da imagem.



Fonte: Elaborado pelo autor.

5.5 Normalização dos Descritores

A normalização é uma técnica frequentemente aplicada como parte da preparação de dados para os algoritmos de aprendizado de máquina (KAUFMAN; ROUSSEEUW, 2009). O objetivo da normalização é alterar os valores dos descritores para serem usados em uma escala comum, sem distorcer as diferenças nos intervalos de valores. Para o aprendizado de máquina, nem todo conjunto de dados requer a normalização. Ela é necessária apenas quando os descritores possuem intervalos diferentes, como os deste trabalho. Por exemplo, os descritores de cor e textura estão em escalas diferentes, podendo ter variações discrepantes entre eles e conseqüentemente ocasionando em uma interpretação errada da relevância que possuem para a tarefa de classificação de úlceras. Quando o valor de um descritor é muito grande em comparação a outro, o classificador tende a ser influenciado intrinsecamente por ele como sendo um preditor mais importante, afetando em seu resultado final. Por este motivo, os valores dos 186 atributos dos descritores extraídos na Seção 5.4 são normalizados para o intervalo numérico entre 0 e 1, da seguinte forma:

$$desc^{ij} = \frac{desc^{ij} - desc_{min}^i}{desc_{max}^i - desc_{min}^i} \quad (26)$$

onde $desc^{ij}$ é o valor do descritor i na posição j , $desc_{min}^i$ e $desc_{max}^i$ é o menor e maior valores do descritor i , respectivamente.

5.6 Redução de Dimensionalidade

Os atributos dos descritores extraídos da Seção 5.4 devem ser avaliados para se selecionarem quais são os mais relevantes para a solução do problema de classificação, método conhecido como redução de dimensionalidade do espaço de características. Segundo Khalid, Khalil e Nasreen (2014), reduzir o número de atributos é uma prática comum para aumentar a velocidade do classificador, remover dados redundantes e irrelevantes, melhorar a visualização dos dados, pode aumentar a acurácia do classificador, entre outros. Portanto, é importante verificar a adequação e relevância dos atributos no contexto do problema.

Existem várias formas de se realizar a redução de dimensionalidade do espaço de características através de técnicas por extração ou seleção. Neste trabalho, a técnica

Tabela 1 – Descritores que melhor representam os superpixels para o SLIC, LSC e SEEDS.

Atributos dos descritores		Métodos		
		SLIC	LSC	SEEDS
Cor	Dominante $L^*a^*b^*$ canal a^*	X		
	Dominante $L^*a^*b^*$ canal L^*		X	
	Dominante RGB canal B	X		
	Dominante RGB canal R		X	
	Dominante RGB Norm. canal B		X	
	Dominante RGB Norm. canal G			X
	Dominante RGB Norm. canal R	X		
	Frequência Pico 1 RGB Norm. canal G			X
	Intensidade Pico 1 $L^*a^*b^*$ canal b^*	X		
	Intensidade Pico 1 Luv canal L			X
	Intensidade Pico 1 RGB Norm. canal B			X
	Média $L^*a^*b^*$ canal b^*		X	
	Média RGB Norm. canal G		X	
	Haralick	Contraste Luv canal u		X
Correlação $L^*a^*b^*$ canal a^*				X
Correlação Luv canal uv			X	
Correlação Luv canal v			X	
Correlação RGB canal R			X	
Correlação RGB canal RG			X	
Energia Luv canal v		X		
Energia RGB canal GB				X
Energia RGB canal R		X		
Entropia Luv canal u		X		
Entropia RGB canal GB				X
Homogeneidade $L^*a^*b^*$ canal a^*			X	
Homogeneidade $L^*a^*b^*$ canal b^*		X		
Homogeneidade Luv canal v			X	
Homogeneidade RGB canal G		X		

Fonte: Elaborado pelo Autor

por seleção de características utilizando o método Wrapper foi escolhida. Essa técnica produz uma quantidade menor de subconjuntos de características quando comparadas com as técnicas por extração (KHALID; KHALIL; NASREEN, 2014). O método Wrapper gera subconjuntos de características e os avaliam usando um classificador, otimizado pela validação cruzada (*cross-validation*) (KOHAVI et al., 1995), que identifica qual o melhor subconjunto baseado em um critério pré-definido. Além disso, o Wrapper também necessita de um motor-de-busca para montar esses subconjuntos. Para o classificador e o motor-de-busca foram escolhidos o algoritmo de árvore de decisão (QUINLAN, 1990) e o algoritmo de pesquisa gulosa *Hill-Climbing* com a estratégia *forward* (NILSSON; NILSSON, 1998), respectivamente. A acurácia foi adotada como critério de avaliação dos subconjuntos formados.

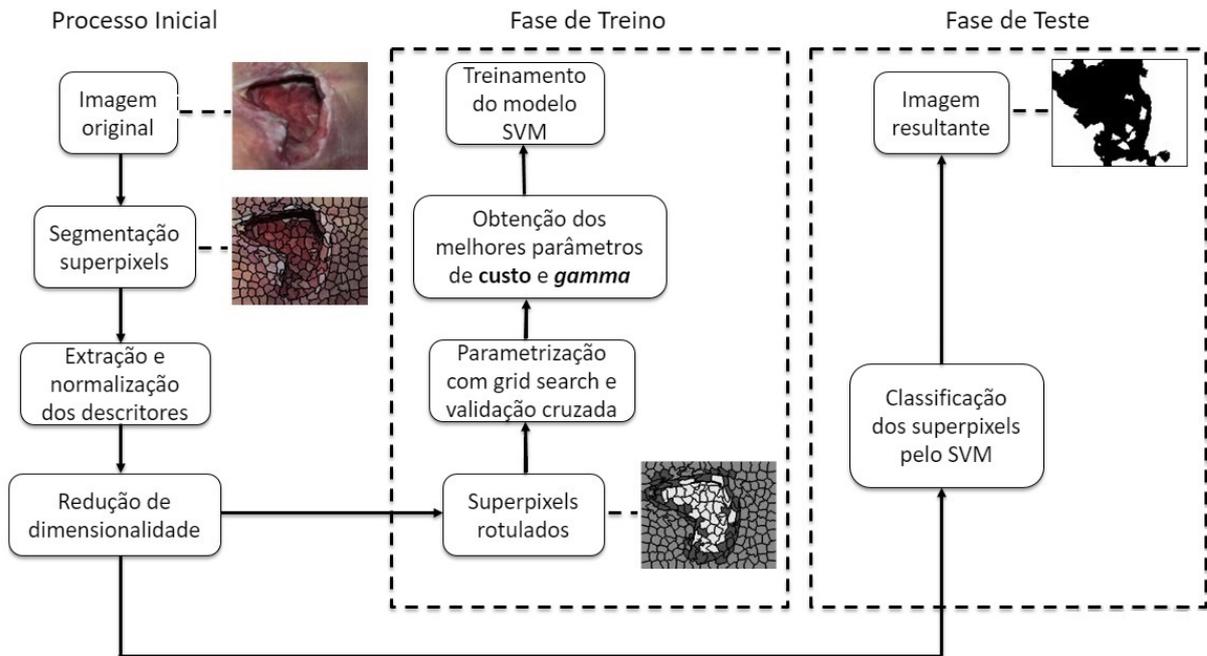
A execução do Wrapper foi realizada através do software de código aberto Weka 3.8 (HALL et al., 2009). Ao realizar a redução de dimensionalidade, os valores dos parâmetros do classificador e do motor-de-busca que o Weka fornece foram mantidos, exceto os valores de limiar e do k-folds da validação-cruzada, que foram alterados para 0,005 e 10, respectivamente. O subconjunto que obteve a maior acurácia com o classificador é selecionado. A Tabela 1 mostra os subconjuntos de atributos selecionados dos descritores que apresentaram a melhor representação dos superpixels para os métodos SLIC, LSC e SEDDS, respectivamente.

5.7 SVM - Parametrização e Classificação

Após a redução de dimensionalidade, os atributos da Tabela 1 formam os vetores de características. Eles servem como entrada para treinar o classificador SVM e também classificar novas instâncias de superpixels em úlcera ou não úlcera. Para cada conjunto de dados segmentados pelas técnicas de superpixels (SLIC, LSC e SEEDS) é criado um modelo SVM. A escolha da função *kernel* é de vital importância para o SVM, ela visa obter uma menor taxa de erro de classificação. O *kernel* RBF mostrou possuir melhor desempenho em trabalhos recentes de feridas crônicas em (VEREDAS et al., 2015) e (WANG et al., 2016). Neste estudo, o RBF foi escolhido como função básica de *kernel* para o SVM. Existem dois parâmetros associados ao *kernel* a serem ajustados: custo (C) e γ . Como o SVM é sensível à parametrização e a escolha dos valores tem grande impacto no resultado final, é necessário a utilização de técnicas que encontrem os melhores valores para esses parâmetros. A melhor combinação dos parâmetros é selecionada por uma pesquisa em grade (*grid search*) utilizando sequências de crescimento exponencial dos dois parâmetros e que são otimizados pela técnica de validação-cruzada (HSU et al., 2003). Cada combinação na grade é utilizada no processo de treinamento do SVM, objetivando identificar os parâmetros ideais que aumentem a acurácia do classificador.

Foi utilizado a biblioteca LibSVM integrado ao software Weka 3.8 para criar os

Figura 22 – Diagrama de treinamento e classificação com SVM.



Fonte: Elaborado pelo Autor.

três modelos SVM e parametriza-los a partir dos atributos dos descritores dispostos na Tabela 1. O software integrado disponibiliza a implementação do *kernel* RBF e as técnicas de *grid search* e validação-cruzada. Durante o *grid search*, foram utilizadas combinações dos seguintes valores: *custo* e *gamma* entre $2^{-10} \rightarrow 2^{10}$ com passos de 0,1 unidade e foram validados através da validação-cruzada em 10-*folds*. Os melhores valores encontrados em cada conjunto segmentado pelo SLIC, LSC e SEEDS, são utilizados no treinamento de seu respectivo modelo SVM. O realce tracejado no centro da Figura 22 (Fase de Treino) mostra o procedimento realizado.

O processo de classificação foi implementado utilizando a linguagem de programação Java 8 e a biblioteca LibSVM. A classificação dos superpixels do conjunto de teste, previamente separado e composto por 21 imagens (20% da base), é realizada pelo SVM, cujo a saída é uma imagem binária com valor 0 (cor preta) representando regiões de úlcera e valor 255 (cor branca) representando regiões de não úlcera. O realce tracejado a direita da Figura 22 (Fase de Teste) mostra o procedimento realizado.

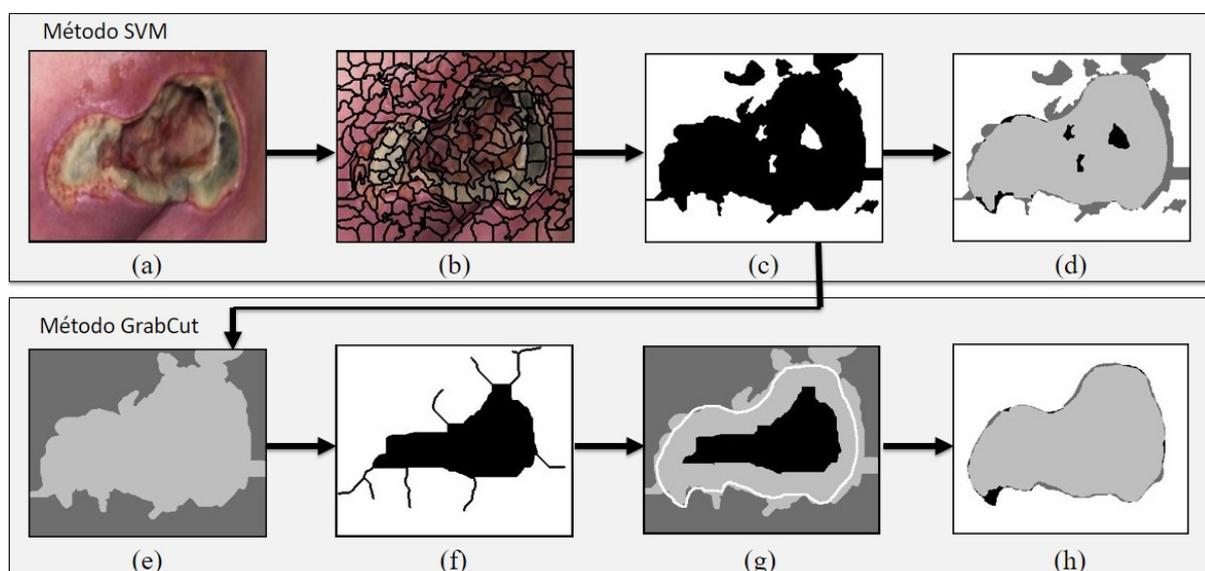
5.8 Segmentação com GrabCut

No método proposto, o método iterativo de segmentação Grabcut foi modificado para aproveitar a classificação realizada pelo SVM. Uma máscara é criada a partir dos resultados obtidos da classificação, substituindo as interações que o usuário teria que realizar no GrabCut para segmentar a úlcera. Com esse procedimento, a segmentação se torna em um processo totalmente automático. A criação da máscara é descrita a seguir.

- a) O filtro morfológico de dilatação com elemento estruturante 3 x 3 do tipo cruz é aplicado ao resultado da classificação SVM. O processo de dilatação é capaz de preencher pequenas descontinuidades encontradas entre dois quaisquer superpixels.
- b) O algoritmo de *Canny* (GONZALEZ; WOODS, 2006) é usado para detectar contornos na imagem. Após a detecção, a região abrangida pelo maior contorno fechado recebe o rótulo de provavelmente úlcera e ao seu redor o rótulo de não úlcera.
- c) Outra imagem é criada a partir do contorno fechado da etapa anterior. Essa imagem passa pelo processo de esqueletização de Zhang e Suen (ZHANG; SUEN, 1984), até que 65% de sua área seja erodida. As ramificações das regiões erodidas são excluídas. Por fim, a região remanescente do processo é rotulada como úlcera e é sobreposta à imagem criada na etapa anterior.

A máscara criada é usada pelo GrabCut para informar como o método deve se comportar ao realizar a segmentação, indicando as regiões de úlcera, provavelmente úlcera e não úlcera. A Figura 23 resume todo o processo.

Figura 23 – Processo de criação da máscara e a segmentação da imagem com os métodos SVM e GrabCut. (a) imagem original; (b) Segmentação em superpixels; (c) Classificação gerada pelo SVM; (d) Resultado da classificação do SVM sobreposto à segmentação manual; (e) Região abrangida pelo maior contorno fechado encontrado em (c); (f) Processo de esqueletização da imagem (e); (g) Máscara resultante usada pelo GrabCut. Cinza escuro representa regiões de não úlcera, cinza claro provavelmente úlcera e preto as regiões de úlcera. O contorno branco mostra a forma real da úlcera, segmentada por um enfermeiro para fins de comparação; (h) Resultado da segmentação realizada pelo GrabCut sobreposto à segmentação manual. Em (d) e (h) falsos-positivos em cinza escuro, falsos-negativos em preto e verdadeiros-positivos em cinza claro.



Fonte: Elaborado pelo Autor.

5.9 Métricas de Avaliação

Para avaliar os resultados obtidos neste estudo, as métricas de Sensibilidade (S), Especificidade (E), Precisão (P), Acurácia (A) e Interseção sobre união (I) foram utilizadas e são descritas a seguir.

- a) Sensibilidade avalia a proporção de úlcera detectada pelo método sobre o total da área de úlcera que realmente existe:

$$S = \frac{VP}{VP + FN} \quad (27)$$

- b) Especificidade avalia a proporção de não úlcera detectada pelo método sobre o total da área de não úlcera que realmente existe:

$$E = \frac{VN}{VN + FP} \quad (28)$$

- c) Precisão avalia a proporção da área de úlcera que foi corretamente classificada pela segmentação do método quando comparada com a segmentação manual:

$$P = \frac{VP}{VP + FP} \quad (29)$$

- d) Acurácia avalia o número de pixels que foram corretamente classificados pelo método:

$$A = \frac{VP + VN}{VP + VN + FP + FN} \quad (30)$$

- e) Interseção sobre união estima a similaridade entre a segmentação realizada pelo método com a segmentação manual:

$$I = \frac{VP}{VP + FP + FN} \quad (31)$$

onde VP (Verdadeiro-Positivos) é a quantidade de área da úlcera classificada corretamente, FP (Falso-Positivos) representa a quantidade de área não pertencente à úlcera mas foi classificada equivocadamente como sendo úlcera e FN (Falso-Negativos) representa a quantidade de área afetada por úlcera que foi classificada equivocadamente como não afetada. Além dessas métricas, o Tempo de Execução (TE) também foi computado.

6 EXPERIMENTOS

Neste capítulo serão apresentados os resultados obtidos na segmentação em imagens de úlcera por pressão a partir das técnicas descritas no Capítulo 5. Também serão descritos os valores dos parâmetros que foram ajustados para cada um dos métodos. Os métodos foram implementados na linguagem de programação Java 8 com o auxílio das bibliotecas OpenCV (BRADSKI; KAEHLER, 2008) e libSVM (CHANG; LIN, 2011) e foram executados em um processador AMD Ryzen 5 1400 Quad-Core 3.2GHZ com 8 GB de RAM e sistema operacional Windows 10 Pro de 64 bits.

Três parâmetros precisam ser empiricamente ajustados para realizar a formação dos superpixels: o número de iterações para o critério de convergência do superpixel, o fator de compacidade dos superpixels e a quantidade de superpixels a serem formados nas imagens. O número de iterações foi ajustado para 400 para todos os métodos. Esse número foi escolhido observando-se que já não haviam mais alterações nas formações dos superpixels. O fator de compacidade está relacionado aos diferentes formatos dos superpixels, que afetam a suavidade das fronteiras. Observando que as fronteiras entre os tipos de tecidos no leito da úlcera e entre as regiões de pele e úlcera possuem formatos bastantes irregulares, o fator de compacidade foi ajustado para que cada método tenha melhor aderência entre essas fronteiras. Pôde-se observar que o valor de compacidade afetou levemente a acurácia de validação do classificador SVM. O valor de compacidade para o LSC variou de 0,05 a 0,065, sendo o melhor resultado em 0,06 com um aumento de 0,8% na acurácia do SVM. Para SLIC, o parâmetro variou de 10 a 25, sendo o melhor resultado em 20 com aumento de 0,5% na acurácia do SVM. Por fim, para SEEDS o valor variou de 1 a 4, sendo o melhor resultado em 3 com aumento de 0,6% na acurácia da classificação. As premissas para a seleção dos valores de compacidade foram de acordo com as sugestões dos autores de cada método. O parâmetro relacionado à quantidade de superpixels controla o tamanho da formação dos superpixels, estando altamente relacionado à resolução da imagem. Este parâmetro pode ter um impacto significativo no desempenho do classificador SVM, pois superpixels muito grandes podem ser compostos de tecidos diferentes, enquanto que os muito pequenos levam à segmentação excessiva. Ao comparar os valores sugeridos nos artigos originais com a resolução do conjunto de dados deste trabalho, o número médio ideal de superpixels foi determinado variando o valor do parâmetro entre 15 a 20 nos métodos LSC e SLIC, e de 250 a 350 no SEEDS. No caso do conjunto de dados MEDTEC, essa proporção resultou em aproximadamente 200 superpixels, de modo que os parâmetros dos métodos foram ajustados para fornecer essa quantidade. O número de superpixels por imagem foi de 208 para os métodos LSC e SLIC, ajustando-os ao valor 18, e de 196 no caso do SEEDS, ajustando-o ao valor 300. Os tempos médios de processamento para a formação dos superpixels foram de 5,73 ($\pm 0,11$), 1,65 ($\pm 0,36$) e 0,39 ($\pm 0,02$) segundos, para o LSC, SLIC e SEEDS, respectivamente.

Após a etapa de segmentação em superpixels, cada superpixel resultante foi tratado pelos atributos dos descritores de cor e textura mostrados na Tabela 1, servindo como entrada para o SVM realizar o treinamento e a classificação em úlcera ou não úlcera.

Três modelos do classificador SVM foram criados e treinados, um para cada método de segmentação em superpixels, em seus respectivos conjuntos de treino com 84 imagens. No conjunto de 7900 superpixels formados pelo método SLIC, os parâmetros que alcançaram o melhor desempenho foram $C = 316,23$ e $\gamma = 2,52$, alcançando uma acurácia de 83,6%. Para os 7324 superpixels formados pelo SEEDS, $C = 251,19$ e $\gamma = 6,31$ alcançando uma acurácia de 85,2%. Por fim, para os 7736 superpixels formados pelo LSC, os parâmetros com melhor desempenho foram $C = 7,94$ e $\gamma = 12,59$, alcançando uma acurácia de 86,0%.

O conjunto de testes é composto por 21 imagens, com 4116 superpixels formados pelo SEEDS e 4368 superpixels formados por cada um dos métodos LSC e SLIC. Os atributos dos descritores dos superpixels da Tabela 1 formam a entrada para os classificadores SVM. As imagens resultantes da classificação passam pela etapa de pós-processamento usando-se o método de segmentação GrabCut. Os resultados da classificação com e sem pós-processamento foram comparados com a segmentação manual realizada pelo enfermeiro, na qual as métricas de Sensibilidade (S), Especificidade (E), Precisão (P), Acurácia (A), Intersecção sobre união (I) e tempo de execução (TE) foram computadas.

A Tabela 2 mostra o desempenho que as métricas alcançaram no processo de

Tabela 2 – Média e \pm desvio padrão da Sensibilidade (S), Especificidade (E), Precisão (P), Acurácia (A), Intersecção sobre união (I) e Tempo de Execução (TE) em segundos para os métodos LSC, SLIC e SEEDS.

	%	SVM	TE (s)	SVM+Grab	TE (s)
LSC	S	89,6 \pm 8,0		96,1 \pm 4,4	
	E	82,1 \pm 9,5		95,6 \pm 4,2	
	P	74,9 \pm 10,0	19,5 \pm 0,3	92,6 \pm 5,9	19,9 \pm 0,5
	A	85,3 \pm 6,5		95,8 \pm 2,6	
	I	69,2 \pm 10,8		89,1 \pm 5,9	
SLIC	S	93,3 \pm 9,0		95,0 \pm 5,6	
	E	80,8 \pm 10,3		95,8 \pm 2,7	
	P	74,5 \pm 10,2	8,4 \pm 0,7	92,9 \pm 4,0	8,8 \pm 0,9
	A	86,1 \pm 5,6		95,9 \pm 1,7	
	I	70,7 \pm 10,8		88,4 \pm 7,9	
SEEDS	S	90,7 \pm 8,1		93,7 \pm 7,8	
	E	83,0 \pm 8,8		96,9 \pm 1,8	
	P	76,1 \pm 9,6	7,7 \pm 0,2	94,4 \pm 3,4	8,1 \pm 0,5
	A	86,3 \pm 5,8		96,0 \pm 1,8	
	I	70,6 \pm 10,4		89,0 \pm 7,1	

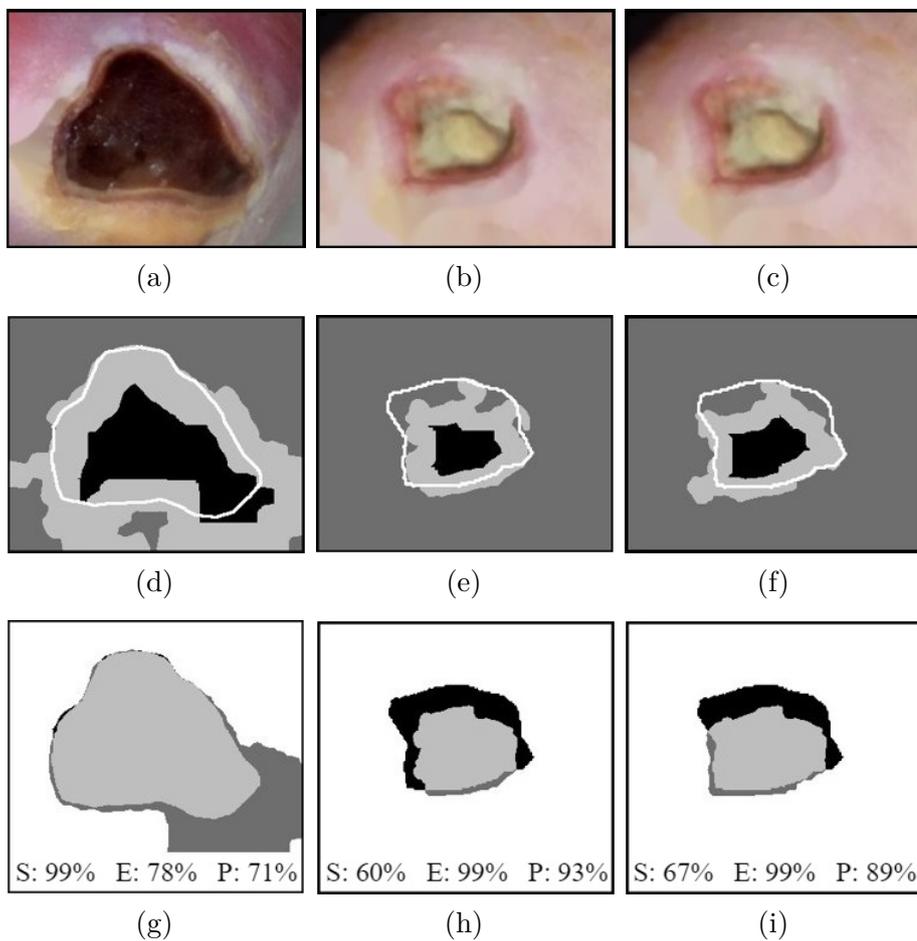
Fonte: Elaborado pelo Autor.

segmentação sem e com pós-processamento (SVM e SVM+Grab, respectivamente), para cada uma das técnicas de segmentação (LSC, SLIC e SEEDS). A avaliação estatística com o teste-t pareado bicaudal indicou uma diferença significativa ($p = 0,04$) para a métrica de especificidade do método SEEDS em comparação com SLIC, quando submetido ao pós-processamento, coluna SVM+Grab. As outras métricas não tiveram diferenças significativas no nível de $\alpha = 0,05$. Portanto, o classificador treinado com os superpixels formados pelo SEEDS provou ser a melhor opção, baseando-se no menor tempo de processamento. Os intervalos de confiança para o desempenho do SEEDS foram calculados no nível de 95% com $S=(92,2,95,2)$, $E=(96,6,97,2)$, $P=(93,8,95,0)$, $A=(95,7,96,3)$ e $I=(87,7,90,3)$.

Os resultados das segmentações são ilustrados nas Figuras 24 e 25 com suas respectivas máscaras e a sobreposição entre a segmentação manual e as geradas pelo GrabCut de cada uma das técnicas SLIC, SEEDS e LSC. A Figura 24 mostra as segmentações que obtiveram os piores resultados. É possível observar a má formação das máscaras geradas a partir do resultado de classificação do SVM. Em (d) existem muitas regiões rotuladas como provavelmente úlcera, que se encontram além do perímetro da ferida. Quando o processo de esqueletização é realizado (Seção 5.8), a máscara resultante mapeia de forma imprecisa a região que representa a úlcera, ultrapassando suas fronteiras. Essa máscara indica erroneamente para que o GrabCut inclua regiões de não úlcera, mostradas em (g). Em (e) e (f) as máscaras resultantes apontam regiões de não úlcera dentro da área de úlcera. Essas máscaras indicam erroneamente que o GrabCut deva excluir essas regiões. Além disso, algumas regiões rotuladas como provavelmente úlcera dentro da área de úlcera, foram segmentadas como não úlcera pelo GrabCut em (h) e (i). Por outro lado, a Figura 25 apresenta as segmentações que obtiveram os melhores resultados. Devido a eficácia da classificação gerada pelo SVM, as regiões de provavelmente úlcera nas máscaras em (d), (e) e (f) acompanham o formato da úlcera e conseqüentemente obtêm uma segmentação mais próxima à manual realizada pelo enfermeiro.

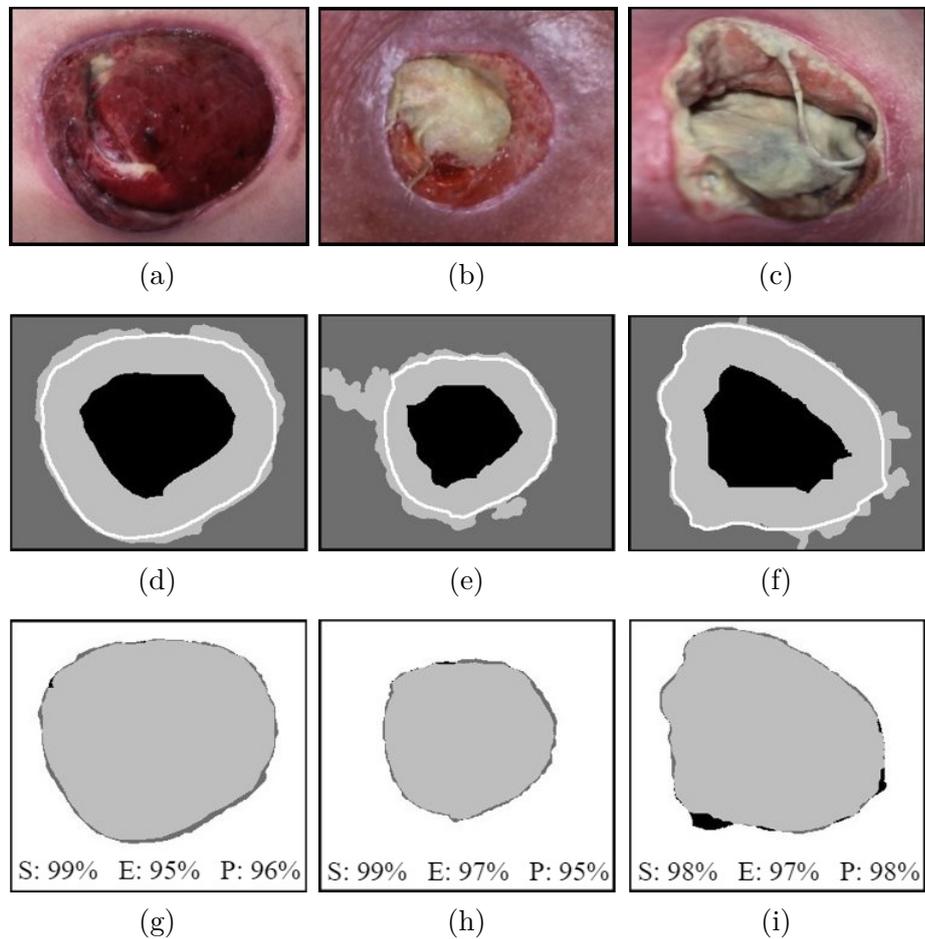
A Figura 26 ilustra a segmentação realizada com o classificador SVM treinado na base do SEEDS e a eficácia do pós-processamento utilizando o GrabCut. Na segunda linha da figura, é possível observar que o classificador teve maiores dificuldades em classificar as regiões de não úlcera (menor especificidade) do que as regiões de úlcera (maior sensibilidade). A baixa especificidade pode ter ocorrido devido a um baixo número de superpixels com essas características de cor e textura na base de dados, ocasionando um aprendizado errado do classificador e conseqüentemente classificando-as erroneamente como sendo úlcera. Na terceira linha, são mostradas as segmentações geradas com o pós-processamento. Comparando os resultados, a melhoria é substancial, ilustrando que a etapa de pós-processamento é robusta o suficiente para remover as regiões de falso-positivos e/ou incluir as regiões de falso-negativos, aumentando a eficácia da segmentação.

Figura 24 – Exemplos de segmentação ineficaz. Imagens originais (linha superior), máscaras (linha do meio) e sobreposição (linha inferior) entre a segmentação manual e os métodos LSC (coluna 1), SLIC (coluna 2) e SEEDS (coluna 3). As máscaras indicam regiões de não úlcera em cinza escuro, provavelmente úlcera em cinza claro e úlcera em preto. Também mostra a forma da ferida traçado em branco. As imagens sobrepostas indicam regiões de falsos negativos em preto, falsos positivos em cinza escuro e verdadeiros positivos em cinza claro. São fornecidas sensibilidade (S), especificidade (E) e precisão (P).



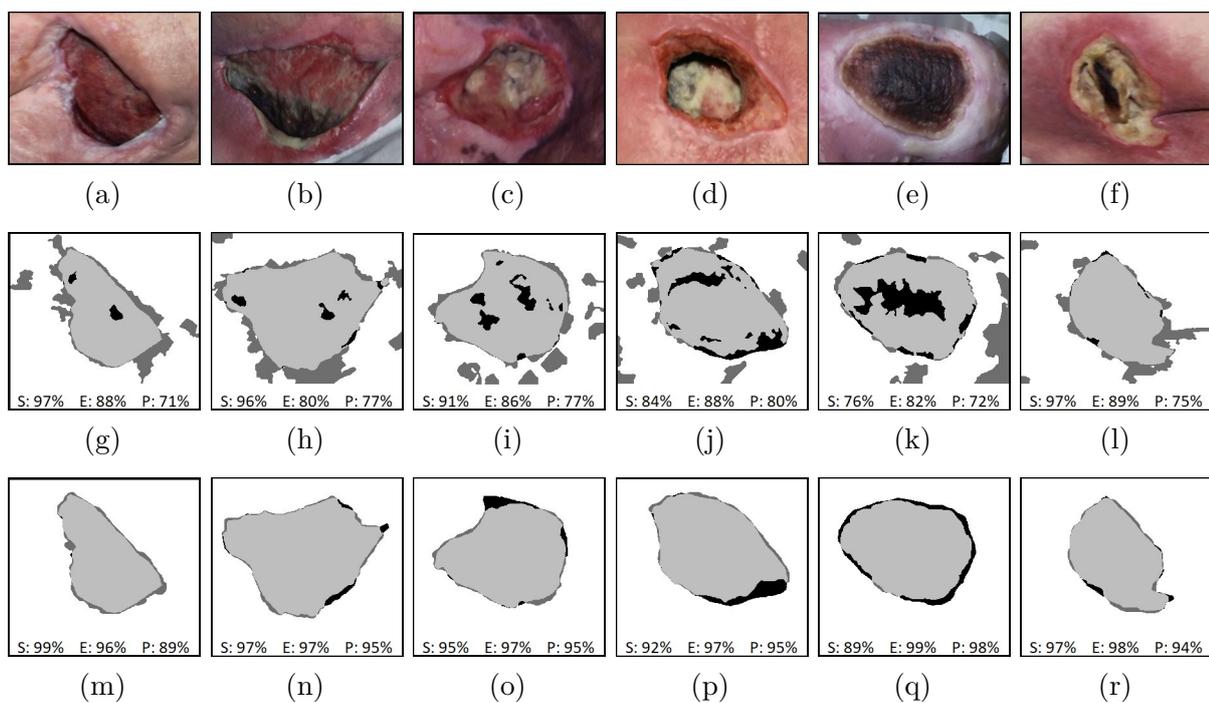
Fonte: Elaborado pelo autor.

Figura 25 – Exemplos de segmentação eficaz. Imagens originais (linha superior), máscaras (linha do meio) e sobreposição (linha inferior) entre a segmentação manual e os métodos LSC (coluna 1), SLIC (coluna 2) e SEEDS (coluna 3). As máscaras indicam regiões de não úlcera em cinza escuro, provavelmente úlcera em cinza claro e úlcera em preto. Também mostra a forma da ferida traçado em branco. As imagens sobrepostas indicam regiões de falsos negativos em preto, falsos positivos em cinza escuro e verdadeiros positivos em cinza claro. São fornecidas sensibilidade (S), especificidade (E) e precisão (P).



Fonte: Elaborado pelo autor.

Figura 26 – Exemplo da eficácia da segmentação com GrabCut utilizando SEEDS. As imagens originais são mostradas na parte superior, os resultados do SVM no meio e os resultados do GrabCut na linha inferior. As imagens indicam regiões de falsos negativos em preto, falsos positivos em cinza escuro e verdadeiros positivos em cinza claro. Sensibilidade (S), Especificidade (E) e Precisão (P) também são fornecidas.



Fonte: Elaborado pelo autor.

7 DISCUSSÃO

Em contraste aos resultados apresentados na Tabela 2 para o método proposto, a Tabela 3 mostra as métricas de desempenho obtidas por outras abordagens relatadas na literatura para a tarefa de segmentação em imagens digitais de lesões crônicas. Embora a comparação de desempenho das métricas não seja uma tarefa simples devido as diferenças nos projetos e nas bases de dados utilizadas, é possível discutir alguns aspectos específicos.

Tabela 3 – Métricas de desempenho relatadas por métodos na literatura para a segmentação em imagens digitais de lesões crônicas.

Referência	Método	Dados [‡]	S	E	P	A	I
Veredas et al. 2009	Mean shift, crescimento de região, NN e Classificadores Bayesianos	113 [*]	78,7	94,7	91,5	–	–
Wannous et al. 2010	J-SEG e SVM	25 [†]	77,0	92,0	–	–	–
Veredas et al. 2015	K-means e SVM	90(23)	–	–	88,1	–	–
Wang et al. 2015	CNN	500(150)	–	–	–	–	47,3
Wang et al. 2016	SLIC, SVM e CRF	100 [*]	73,3	94,6	–	–	–
Liu et al. 2017	CNN e CRF	760(190)	90,6	–	93,3	98,2	84,6
Lu et al. 2017	CNN	300 [†] P	–	–	–	83	–
Dhane et al. 2017	Clusterização espectral Fuzzy	70(70)	87,3	95,7	–	91,5	79,0
Silva et al. 2018	Filtros e operações morfológicas	110(110) P	81,6	–	90,8	81,3	–
Zahia et al. 2018	CNN	18(4)	–	–	–	92,0	–
Li et al. 2018	DNN e filtros	760(190)	–	–	94,7	–	86,3
Li et al. 2019	DNN e filtros	760(190)	–	–	95,0	–	86,5

[‡] Número de imagens de treinamento(teste). Os estudos que usaram apenas conjuntos de dados públicos estão marcados com P.

^{*} Teste baseado em validação-cruzada com 10-*fold*.

[†] O número de imagens para teste não foi relatado.

Métodos: Segmentação J-value (J-SEG); Máquinas de Vetores de Suporte (SVM); Rede Neural (NN); Rede Neural Convolutacional (CNN); Simple Linear Iterative Clustering (SLIC); Conditional Random Field (CRF). Rede Neural Profunda (DNN);

Métricas: Sensitividade (S); Especificidade (E); Precisão (P); Acurácia (A); Interseção sobre União (I).

Fonte: Elaborado pelo Autor.

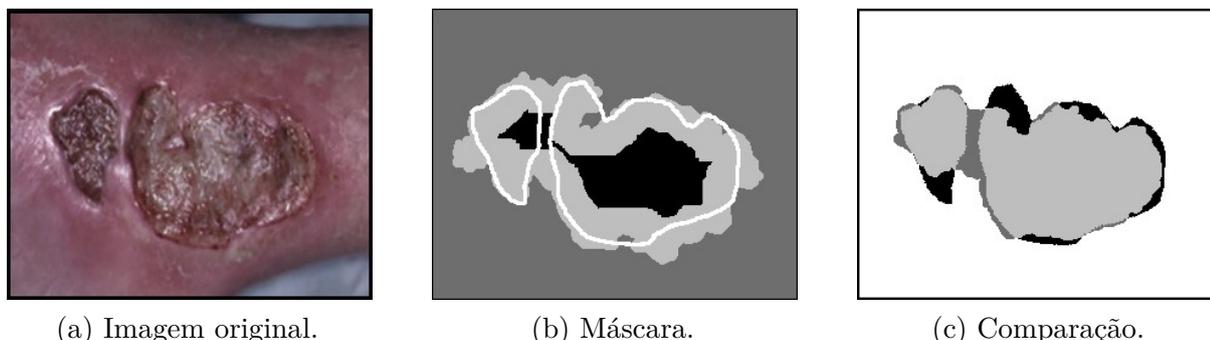
Primeiramente, pode-se observar o uso variado de métricas de desempenho entre os trabalhos revisados na literatura. Embora seja sabido que uma única métrica não é capaz de caracterizar o desempenho da segmentação, 4 dos 12 trabalhos revisados foram avaliados com base em um único índice e apenas 1/3 relataram mais de 2 métricas. Desconsiderando outros elementos de comparação, o método proposto alcançou a maior sensibilidade, especificidade e interseção sobre a união entre os trabalhos relacionados. Foi também o segundo melhor em relação à acurácia e o terceiro com a melhor precisão.

A comparação de desempenho também depende do conjunto de dados. Quando as

imagens são obtidas de conjuntos de dados privados, a reprodutibilidade não é possível. A partir da literatura revisada, apenas os trabalhos de (LU et al., 2017) e (SILVA; MACHADO, 2018) usaram conjuntos de dados públicos. Além disso, o tamanho da base de dados necessária para treinar métodos de aprendizado profundo é geralmente muito maior do que o necessário para outras técnicas de aprendizado de máquina. O método proposto foi treinado e testado usando um conjunto de dados público e apresentou menor acurácia e precisão somente quando comparado aos trabalhos de (LIU et al., 2017) e (LI et al., 2018), que foram testados em conjuntos de dados privados. Mesmo neste caso, o método proposto no presente trabalho apresentou maior sensibilidade, especificidade e interseção sobre união.

A principal desvantagem do método proposto em relação aos trabalhos baseados em aprendizado profundo (LIU et al., 2017), (LI et al., 2018) e (LI et al., 2019), é com relação a segmentação de imagens com úlcera composta. A Figura 27 ilustra o comportamento do método proposto ao tentar realizar a segmentação dessas imagens. É possível observar a má formação da máscara em (b), que rotulou regiões de provavelmente úlcera (cinza claro) além dos perímetros demarcados pelo enfermeiro (traçado em branco). Quando o processo de esqueletização é realizado (Seção 5.8), a máscara resultante mapeia de forma imprecisa as regiões que representam a úlcera (cor preta), ultrapassando as fronteiras dos perímetros. Isso acontece devido às etapas (a) e (b) da Seção 5.8, que realiza a dilatação para preenchimento de pequenas descontinuidades encontradas entre dois quaisquer superpixels e a seleção da região abrangida pelo maior contorno fechado, respectivamente. Em (c) é realizada a comparação com a segmentação manual, com as regiões de verdadeiros positivos em cinza claro, falsos positivos em cinza escuro e falsos negativos em preto.

Figura 27 – Exemplo de segmentação de imagem com úlcera composta. (a) Imagem original. (b) Máscara resultante usada pelo GrabCut. A máscara indica regiões de não úlcera em cinza escuro, provavelmente úlcera em cinza claro e úlcera em preto. Contorno branco indica a forma real da úlcera, segmentado pelo enfermeiro. (c) Sobreposição com a segmentação manual, falsos-positivos em cinza escuro, falsos-negativos em preto e verdadeiros-positivos em cinza claro.



(a) Imagem original.

(b) Máscara.

(c) Comparação.

Fonte: Elaborado pelo Autor.

Em contrapartida, dos trabalhos baseados em aprendizado profundo, nenhum superou o método proposto em mais de uma métrica. No caso da precisão, a diferença para o algoritmo melhor avaliado foi de apenas 0,6% em (LI et al., 2019). Com relação à acurácia, o trabalho de (LIU et al., 2017) superou nossa abordagem em 2,2%, mas apresentou 3,1% menos sensibilidade, 1,1% menos precisão e 4,4% menos interseção sobre a união. Esses resultados são relevantes, pois os métodos de aprendizado profundo podem não ter explicação, além de exigir processamento intensivo. No caso da análise de imagens médicas, é desejável que os resultados possam ser explicados e o comportamento dos métodos previstos em relação ao seu sucesso ou fracasso.

8 CONCLUSÃO

Neste trabalho foi apresentado um método para segmentar úlceras por pressão de forma automática em imagens digitais com vistas à extração da área da lesão. Ele combina o uso de filtros clássicos, clusterização não supervisionada, extração de características, redução de dimensionalidade e algoritmos supervisionados de aprendizagem de máquina. Aplicado a um conjunto de dados público, o método conseguiu superar trabalhos publicados recentemente com base em arquiteturas de aprendizado profundo, sem o processamento intensivo e quantidade elevada de dados de treino que eles necessitam. A importância do tema abordado pôde ser comprovada pelas recentes publicações levantadas e pelos esforços no desenvolvimento de novas técnicas e ferramentas computacionais que visam contribuir no quesito de monitoramento da redução da área de lesões crônicas, aspecto relevante para avaliar a evolução cicatricial e acabar com a subjetividade entre os enfermeiros.

O desenvolvimento de um método computacional para mensuração das úlceras é uma tarefa desafiadora devido à complexidade que essas lesões podem apresentar, como os vários tipos de tecidos e suas respectivas cores, bem como a forma irregular de seus contornos. Embora o método proposto tente realizar a identificação do contorno da úlcera o mais próximo do delineamento manual, há casos que divergências ocorrerão. No entanto, espera-se que o método proposto seja suficiente para atingir uma precisão comparável à variação natural da delimitação realizada pelo mesmo enfermeiro em diferentes momentos, bem como à variação observada em múltiplos enfermeiros (MAYROVITZ; SOONTUPE, 2009).

Atualmente, não há uma base pública de imagens de lesões que tenha critérios de padronização de captura e com anotações realizadas por profissionais que indicam regiões de úlcera e não úlcera. Isso se torna uma grande barreira para o treinamento de métodos baseados em aprendizagem de máquina e também para realizar comparações diretas dos resultados entre os trabalhos na literatura. Apesar do fato de que o método proposto foi treinado e testado em uma base de imagens sem padronizações de captura, ele alcançou resultados significativos, possibilitando equiparar os resultados com trabalhos na literatura que utilizaram arquiteturas de aprendizado profundo.

A principal contribuição deste trabalho está na identificação do contorno mais preciso da lesão enquanto relacionado à aplicação do método GrabCut como forma de pós-processamento, que foi capaz de aumentar de forma significativa a efetividade da segmentação. Nos trabalhos revisados na literatura, utilizou-se filtros morfológicos e/ou CRF (*Conditional Random Field*) para realização desse procedimento. Destaca-se também que esse procedimento é facilmente expansível para trabalhos que necessitam extrair objetos de interesse em imagens digitais, bastando criar uma máscara que informe como o GrabCut deverá proceder para realização da segmentação.

Como contribuições adicionais, destacam-se a avaliação de três métodos de segmentação não supervisionado que utilizam a estratégia por superpixels na tarefa de segmentação e extração de descritores de características e, destaca-se também, a combinação de diversos descritores selecionados a partir de trabalhos da literatura e que foram avaliados e filtrados através do método de redução de dimensionalidade Wrapper. Dessa forma, buscou-se contribuir para o aperfeiçoamento das técnicas de segmentação de úlceras em imagens digitais com vistas à extração da área da lesão, fornecendo uma alternativa de acompanhamento da evolução cicatricial durante o período de tratamento dos pacientes.

Este trabalho é um aprimoramento do artigo "*A Computational Method for Semi-Automatic Measurement of Pressure Ulcers*", publicado na Revista "*Wound Repair and Regeneration*" (SILVA; MACHADO, 2018) – Qualis A1. A vantagem do método apresentado neste trabalho para com o artigo está no processo de segmentação automático e maior efetividade da segmentação (Tabela 4).

Tabela 4 – Métricas de desempenho entre os trabalhos desenvolvidos.

Método	Dados‡	S	E	P	A	I
Silva e Machado (2018)	110(110) P	81,6	-	90,8	81,3	-
Proposto	84(21) P	93,7	96,9	94,4	96,0	89,0

‡ Número de imagens de treinamento(teste). Utilização de dados públicos estão marcados com P.
Métricas: Sensitividade (S); Especificidade (E); Precisão (P); Acurácia (A); Interseção sobre União (I).

Fonte: Elaborado pelo Autor.

O processo de desenvolvimento desta pesquisa permitiu a submissão do artigo "*Automatic measurement of pressure ulcers using Support Vector Machines and GrabCut*" na Revista "*Computer Methods and Programs in Biomedicine*" – Qualis A1.

Para trabalhos futuros sugere-se adaptar o método para realização da classificação dos tipos de tecidos presentes no leito da úlcera, adicionando ao método mais um recurso de avaliação cicatricial. Também seria interessante, a partir de uma base de dados maior, treinar uma rede neural convolucional combinando-a com a etapa de pós-processamento descrito neste trabalho e verificar se há aumento no valor das métricas de desempenho. Um aspecto a ser investigado é a eficácia do método na avaliação de outros tipos de lesões crônicas, além das úlceras por pressão.

REFERÊNCIAS

- ACHANTA, R. et al. Slic superpixels compared to state-of-the-art superpixel methods. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 34, n. 11, p. 2274–2282, 2012. Citado 3 vezes nas páginas 26, 38 e 39.
- AHN, C. et al. Advances in wound photography and assessment methods. **Advances in skin & wound care**, LWW, v. 21, n. 2, p. 85–93, 2008. Citado 2 vezes nas páginas 32 e 33.
- ARVIS, V. et al. Generalization of the cooccurrence matrix for colour images: application to colour texture classification. **Image Analysis & Stereology**, v. 23, n. 1, p. 63–72, 2004. Citado na página 53.
- BERGH, M. Van den et al. Seeds: Superpixels extracted via energy-driven sampling. **International Journal of Computer Vision**, Springer, v. 111, n. 3, p. 298–314, 2015. Citado na página 39.
- BRADSKI, G.; KAEHLER, A. **Learning OpenCV: Computer vision with the OpenCV library**. [S.l.]: "O'Reilly Media, Inc.", 2008. Citado na página 61.
- CHANG, C.-C.; LIN, C.-J. Libsvm: A library for support vector machines. **ACM transactions on intelligent systems and technology (TIST)**, Acm New York, NY, USA, v. 2, n. 3, p. 1–27, 2011. Software disponível em: <<http://www.csie.ntu.edu.tw/~cjlin/libsvm>>. Citado na página 61.
- COMANICIU, D.; MEER, P. Mean shift: A robust approach toward feature space analysis. **IEEE Transactions on pattern analysis and machine intelligence**, IEEE, v. 24, n. 5, p. 603–619, 2002. Citado na página 26.
- DEMARRÉ, L. et al. The cost of pressure ulcer prevention and treatment in hospitals and nursing homes in flanders: A cost-of-illness study. **Int. J. Nurs. Stud.**, Elsevier, v. 52, n. 7, p. 1166–79, 2015. Citado na página 21.
- DENG, Y.; MANJUNATH, B. Unsupervised segmentation of color-texture regions in images and video. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 23, n. 8, p. 800–810, 2001. Citado na página 25.
- DHANE, D. M. et al. Fuzzy spectral clustering for automated delineation of chronic wound region using digital images. **Computers in biology and medicine**, Elsevier, v. 89, p. 551–560, 2017. Citado na página 25.
- EDSBERG, L. et al. Revised national pressure ulcer advisory panel pressure injury staging system: revised pressure injury staging system. **J. Wound Ostomy. Continence Nurs.**, Wolters Kluwer Health, v. 43, n. 6, p. 585, 2016. Citado 3 vezes nas páginas 21, 31 e 32.
- GETHIN, G. The importance of continuous wound measuring. **Wounds UK**, v. 2, n. 2, p. 60, 2006. Citado 2 vezes nas páginas 21 e 32.
- GONZALEZ, R.; WOODS, R. **Digital Image Processing (3rd Edition)**. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006. ISBN 013168728X. Citado 7 vezes nas páginas 35, 36, 40, 41, 49, 53 e 58.

GOSWAMI, J. C.; CHAN, A. K. **Fundamentals of wavelets: theory, algorithms, and applications**. [S.l.]: John Wiley & Sons, 2011. v. 233. Citado 2 vezes nas páginas 43 e 53.

GREY, J. E.; HARDING, K. G.; ENOCH, S. Pressure ulcers. **Bmj**, British Medical Journal Publishing Group, v. 332, n. 7539, p. 472–475, 2006. Citado 3 vezes nas páginas 21, 30 e 31.

GUILLEMOT, C.; MEUR, O. L. Image inpainting: Overview and recent advances. **IEEE signal processing magazine**, IEEE, v. 31, n. 1, p. 127–144, 2013. Citado na página 48.

HALL, M. et al. The weka data mining software: an update. **ACM SIGKDD explorations newsletter**, ACM New York, NY, USA, v. 11, n. 1, p. 10–18, 2009. Citado na página 56.

HARALICK, R. M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, IEEE, v. 67, n. 5, p. 786–804, 1979. Citado na página 41.

HOWARD, A. G. et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. **arXiv preprint arXiv:1704.04861**, 2017. Citado na página 26.

HSU, C.-W. et al. A practical guide to support vector classification. Taipei, 2003. Citado na página 56.

IBRAHEEM, N. A. et al. Understanding color models: a review. **ARPN Journal of science and technology**, Citeseer, v. 2, n. 3, p. 265–275, 2012. Citado 3 vezes nas páginas 35, 36 e 37.

JØRGENSEN, L. B. et al. Methods to assess area and volume of wounds—a systematic review. **International wound journal**, Wiley Online Library, v. 13, n. 4, p. 540–553, 2016. Citado na página 21.

KAUFMAN, L.; ROUSSEEUW, P. J. **Finding groups in data: an introduction to cluster analysis**. [S.l.]: John Wiley & Sons, 2009. v. 344. Citado na página 54.

KEAST, D. et al. Measure: A proposed assessment framework for developing best practice recommendations for wound assessment. **Wound Repair Regen**, Wiley Online Library, v. 12, n. s1, p. s1–s17, 2004. Citado 2 vezes nas páginas 21 e 32.

KHALID, S.; KHALIL, T.; NASREEN, S. A survey of feature selection and feature extraction techniques in machine learning. In: IEEE. **2014 Science and Information Conference**. [S.l.], 2014. p. 372–378. Citado 2 vezes nas páginas 55 e 56.

KOHAVI, R. et al. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: MONTREAL, CANADA. **Ijcai**. [S.l.], 1995. v. 14, n. 2, p. 1137–1145. Citado na página 56.

KUDVA, V.; PRASAD, K.; GURUVARE, S. Detection of specular reflection and segmentation of cervix region in uterine cervix images for cervical cancer screening. **Irbm**, Elsevier, v. 38, n. 5, p. 281–291, 2017. Citado 2 vezes nas páginas 50 e 51.

LI, F. et al. A composite model of wound segmentation based on traditional methods and deep neural networks. **Computational intelligence and neuroscience**, Hindawi, v. 2018, 2018. Citado 2 vezes nas páginas 27 e 68.

LI, F. et al. Wound segmentation network based on location information enhancement. **IEEE Access**, IEEE, v. 7, p. 87223–87232, 2019. Citado 3 vezes nas páginas 27, 68 e 69.

LI, Z.; CHEN, J. Superpixel segmentation using linear spectral clustering. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2015. p. 1356–1363. Citado 2 vezes nas páginas 38 e 39.

LITJENS, G. et al. A survey on deep learning in medical image analysis. **Medical image analysis**, Elsevier, v. 42, p. 60–88, 2017. Citado na página 26.

LIU, X. et al. A framework of wound segmentation based on deep convolutional networks. In: IEEE. **2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)**. [S.l.], 2017. p. 1–7. Citado 3 vezes nas páginas 26, 68 e 69.

LU, H. et al. Wound intensity correction and segmentation with convolutional neural networks. **Concurrency and computation: practice and experience**, Wiley Online Library, v. 29, n. 6, p. e3927, 2017. Citado 2 vezes nas páginas 26 e 68.

MAYROVITZ, H. N.; SOONTUPE, L. B. Wound areas by computerized planimetry of digital images: accuracy and reliability. **Advances in skin & wound care**, LWW, v. 22, n. 5, p. 222–229, 2009. Citado na página 71.

MEDETEC. **Wound Database: stock pictures of wounds**. [S.l.: s.n.], 2007. Disponível em: <http://www.medetec.co.uk/index.html>. Acessado em 10 de Maio, 2020. Citado 2 vezes nas páginas 23 e 49.

Ministério da Saúde do Brasil. **Manual de condutas para úlceras neurotróficas e traumáticas**. 2. ed. Brasília: Série J. Caderno de Reabilitação em Hanseníase, 2002. Disponível em: <http://www.saudedireta.com.br/docsupload/1340224713manual_feridas_final.pdf>. Citado 2 vezes nas páginas 21 e 29.

NILSSON, N. J.; NILSSON, N. J. **Artificial intelligence: a new synthesis**. [S.l.]: Morgan Kaufmann, 1998. Citado na página 56.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **IEEE Transactions on pattern analysis and machine intelligence**, IEEE, v. 24, n. 7, p. 971–987, 2002. Citado na página 42.

PAPAZOGLU, E. S. et al. Image analysis of chronic wounds for determining the surface area. **Wound repair and regeneration**, Wiley Online Library, v. 18, n. 4, p. 349–358, 2010. Citado na página 25.

PEREIRA, S. M. et al. Classification of color images of dermatological ulcers. **IEEE journal of biomedical and health informatics**, IEEE, v. 17, n. 1, p. 136–142, 2013. Citado na página 52.

PEREZ, A. A.; GONZAGA, A.; ALVES, J. M. Segmentation and analysis of leg ulcers color images. In: IEEE. **Proceedings International Workshop on Medical Imaging and Augmented Reality**. [S.l.], 2001. p. 262–266. Citado na página 25.

QUINLAN, J. R. Decision trees and decision-making. **IEEE Transactions on Systems, Man, and Cybernetics**, IEEE, v. 20, n. 2, p. 339–346, 1990. Citado na página 56.

- ROTHER, C.; KOLMOGOROV, V.; BLAKE, A. Grabcut: interactive foreground extraction using iterated graph cuts. **ACM transactions on graphics (TOG)**, ACM New York, NY, USA, v. 23, n. 3, p. 309–314, 2004. Citado 2 vezes nas páginas 46 e 47.
- SCHNEIDER, C. A.; RASBAND, W. S.; ELICEIRI, K. W. Nih image to imagej: 25 years of image analysis. **Nature methods**, Nature Publishing Group, v. 9, n. 7, p. 671–675, 2012. Citado na página 51.
- SILVA, R. H.; MACHADO, A. M. A computational method for semi-automatic measurement of pressure ulcers. **Wound Repair and Regeneration**, Wiley Online Library, v. 26, n. 4, p. 332–339, 2018. Citado 4 vezes nas páginas 22, 25, 68 e 72.
- TELEA, A. An image inpainting technique based on the fast marching method. **Journal of graphics tools**, Taylor & Francis, v. 9, n. 1, p. 23–34, 2004. Citado 2 vezes nas páginas 48 e 51.
- VAPNIK, V. N. **The nature of statistical learning theory**. [S.l.]: Springer science & business media, 1995. v. 21. Citado na página 44.
- VEREDAS, F.; MESA, H.; MORENTE, L. Binary tissue classification on wound images with neural networks and bayesian classifiers. **IEEE transactions on medical imaging**, IEEE, v. 29, n. 2, p. 410–427, 2009. Citado 2 vezes nas páginas 26 e 52.
- VEREDAS, F. J. et al. Wound image evaluation with machine learning. **Neurocomputing**, Elsevier, v. 164, p. 112–122, 2015. Citado 2 vezes nas páginas 26 e 56.
- VEREDAS, F. J.; MESA, H.; MORENTE, L. Efficient detection of wound-bed and peripheral skin with statistical colour models. **Medical & biological engineering & computing**, Springer, v. 53, n. 4, p. 345–359, 2015. Citado na página 38.
- VEZHNEVETS, V.; SAZONOV, V.; ANDREEVA, A. A survey on pixel-based skin color detection techniques. In: MOSCOW, RUSSIA. **Proc. Graphicon**. [S.l.], 2003. v. 3, p. 85–92. Citado na página 38.
- WANG, C. et al. A unified framework for automatic wound segmentation and analysis with deep convolutional neural networks. In: IEEE. **2015 37th annual international conference of the IEEE engineering in medicine and biology society (EMBC)**. [S.l.], 2015. p. 2415–2418. Citado 2 vezes nas páginas 22 e 26.
- WANG, L. **Support vector machines: theory and applications**. [S.l.]: Springer Science & Business Media, 2005. v. 177. Citado na página 45.
- WANG, L. et al. Area determination of diabetic foot ulcer images using a cascaded two-stage svm-based classification. **IEEE Transactions on Biomedical Engineering**, IEEE, v. 64, n. 9, p. 2098–2109, 2016. Citado 4 vezes nas páginas 26, 38, 52 e 56.
- WANNOUS, H.; LUCAS, Y.; TREUILLET, S. Enhanced assessment of the wound-healing process by accurate multiview tissue classification. **IEEE transactions on Medical Imaging**, IEEE, v. 30, n. 2, p. 315–326, 2010. Citado na página 26.
- WANNOUS, H.; TREUILLET, S.; LUCAS, Y. Robust tissue classification for reproducible wound assessment in telemedicine environments. **Journal of Electronic Imaging**, International Society for Optics and Photonics, v. 19, n. 2, p. 023002, 2010. Citado 3 vezes nas páginas 25, 38 e 52.

WU, K.-P.; WANG, S.-D. Choosing the kernel parameters for support vector machines by the inter-cluster distance in the feature space. **Pattern Recognition**, Elsevier, v. 42, n. 5, p. 710–717, 2009. Citado na página 46.

YI, F.; MOON, I. Image segmentation: A survey of graph-cut methods. In: IEEE. **2012 International Conference on Systems and Informatics (ICSAI2012)**. [S.l.], 2012. p. 1936–1941. Citado 2 vezes nas páginas 46 e 47.

ZAHIA, S. et al. Tissue classification and segmentation of pressure injuries using convolutional neural networks. **Computer methods and programs in biomedicine**, Elsevier, v. 159, p. 51–58, 2018. Citado 2 vezes nas páginas 22 e 26.

ZHANG, T.; SUEN, C. Y. A fast parallel algorithm for thinning digital patterns. **Communications of the ACM**, ACM New York, NY, USA, v. 27, n. 3, p. 236–239, 1984. Citado na página 58.