



Universidade de Brasília – UnB

Faculdade UnB Gama – FGA

Engenharia Eletrônica

Dimensionamento e análise de feridas utilizando o método de segmentação SLIC.

Autor: Danovan Martins de Sousa

Orientador: Prof. Renan Utida Barbosa Ferreira, Dr

Brasília, DF

2019



Danovan Martins de Sousa

**Dimensionamento e análise de feridas utilizando o
método de segmentação SLIC.**

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica.

Universidade de Brasília – UnB

Faculdade UnB Gama – FGA

Orientador: Prof. Renan Utida Barbosa Ferreira, Dr

Brasília, DF

2019

Danovan Martins de Sousa

Dimensionamento e análise de feridas utilizando o método de segmentação SLIC./ Danovan Martins de Sousa. – Brasília, DF, 2019-
Orientador: Prof. Renan Utida Barbosa Ferreira, Dr

Trabalho de Conclusão de Curso – Universidade de Brasília – UnB
Faculdade UnB Gama – FGA , 2019.

1. Processamento digital de imagens. 2. método SLIC. I. Prof. Renan Utida
Barbosa Ferreira, Dr. II. Universidade de Brasília. III. Faculdade UnB Gama. IV.
Dimensionamento e análise de feridas utilizando o método de segmentação SLIC.

Danovan Martins de Sousa

Dimensionamento e análise de feridas utilizando o método de segmentação SLIC.

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica.

Aprovado por:

Prof. Renan Utida Barbosa Ferreira,
Dr
Orientador

Prof. Marcus Vinícius Chaffim Costa,
Dr
Convidado 1

Profa. Luzia Sousa Ferreira, Esp
Convidado 2

Brasília, DF

2019

Dedico este trabalho aos jovens estudantes que lutam para melhorar o estado de pessoas debilitadas, pois estes são capazes de permitir que um sorriso venha a ser expresso uma outra vez.

Agradecimentos

Gostaria de agradecer a minha mãe, por ser a inspiração do meu início de dia. Por sempre ter me apoiado nos momentos mais difíceis de minha vida, fazendo o possível para me trazer um sorriso.

A minha família por me apoiar em momentos de dificuldade, por me dar forças ao longo do curso de Engenharia Eletrônica.

Ao professor Renan Utida Ferreira que me proporcionou a oportunidade de realizar o trabalho de conclusão de curso na área de processamento digital, me incentivando e sendo um grande amigo.

Agradeço a todos os outros professores que me apoiaram ao longo da minha caminhada como estudante, principalmente ao professor Cristiano Jacques Miosso e professora Suélia Fleury Rodrigues, pelo ensino, companheirismo e suporte durante o curso.

Aos meus amigos e companheiros de curso que sempre me agraciaram com momentos inesquecíveis durante minha jornada.

O semblante diz muito a respeito do estado atual de uma pessoa.

Um sorriso é suficiente para contagiar o ambiente ao redor,

trazendo consigo energias positivas.

Portanto, molde o seu redor e alegre teu dia.

Seja feliz!

Resumo

As feridas são definidas como interrupções da integridade cutâneo-mucosa e ocorrem por meio de um corte ou fissura na epiderme, podendo esta perfuração se alastrar por meio dos músculos, articulações, cartilagens, tendões, ligamentos, ossos, órgãos cavitários etc. A cicatrização de uma ferida ocorre ao início da lesão com o processo de coagulação, responsável por evitar a perda excessiva de sangue do corpo. No caso de um ferimento agudo, o processo de cicatrização, em geral, ocorre sem problemas, possibilitando a recuperação em alguns dias. Já as feridas crônicas necessitam de acompanhamento especializado para seu tratamento, pois em maior parte estão associadas a algum tipo de doença pré-existente e ocorrem por complicações presentes no sistema vascular, comprometendo a recuperação pelo processo de coagulação. Durante a cicatrização, as cores dos tecidos na região lesionada trazem grande influência para o correto tratamento da ferida, pois cada cor tem seu aspecto próprio para que ocorra a cicatrização da região lesionada. Dessa forma, é possível evidenciar a necessidade de providenciar um algoritmo capaz de auxiliar na realização de tratamentos de feridas, separando os tipos de tecidos existentes e suas respectivas dimensões.

A manipulação de imagens é um processo utilizado para filtrar informações de interesse contidas em uma imagem, bem como criar um quadro com informações sobre a área da região lesionada, possibilitando a segmentação dos diferentes tipos de tecidos existentes na região afetada. Por meio de técnicas de processamento digital de imagens, pode-se realizar o dimensionamento de feridas e a classificação de regiões por cores utilizando o método *simple linear iterative clustering* (SLIC, sigla em inglês). Os dados obtidos serão tratados em uma interface que é responsável por facilitar a interação entre usuário e máquina, fazendo com que todo o conjunto de informações armazenados em um banco de dados possa ser manipulado para exibir as dimensões e os diferentes tipos de tecidos existentes em cada aquisição realizada. Resultados mostram que a ferramenta gera resultados compatíveis com métodos de segmentação automática, porém com a vantagem de permitir ao profissional de saúde atuação direta em manipular a região segmentada.

Palavras-chave: Cicatrização de feridas, coloração de feridas, processamento digital de imagens, dimensionamento de feridas, *simple linear iterative clustering*.

Abstract

The wounds are defined as disruption of cutaneous-mucosal integrity and they occur through a cut or cleft in the epidermis, and this cut can spread through the muscles, joints, cartilage, tendons, ligaments, bones, cavity organs and others. There are two types of injury, acute and chronic. The main symptom is an intense pain in the area due the contact with the nerves, which can occur through touch or bacteria's actions. The treatment proceeds at the beginning of the injury with the clotting process, responsible for preventing excessive blood loss from the body. In the case of an acute injury, the healing process occurs without problems, enabling recovery in a few days. Otherwise, the chronic injury requires specialized monitoring for treatment, as most are associated with some sort of pre-existing disease and occur through complications in the vascular system, jeopardizing the recovery coagulation process. The injured region's coloration brings great influence to the correct treatment of the wound, because each color has its own aspect for the healing of the injured area. This way, it is evidence of the need to provide an algorithm capable of assisting in the realization of wound care by separating existing tissue types and their dimensions.

Image manipulation is a process capable of filtering information of continuous interest in an image, as well as creating a frame with information about the area of the region allowing the segmentation of the different tissue types in the region affected. Through digital image processing techniques, one can perform the wound measurement and region classification by color using the simple method linear iterative clustering (SLIC). The data obtained will be processed in an interface that is responsible for facilitating user-machine interaction, causing the entire set of information stored in a database can be manipulated to display the dimensions and different types of fabrics in each acquisition made. Results show that the tool generates results compatible with automatic segmentation methods, but with the advantage of allowing health professionals to act directly in manipulating the segmented region.

Key-words: wound healing, wound coloring. digital image processing, scaling of wounds, simple linear iterative clustering.

Lista de figuras

Figura 2.1 – Representação dos diferentes tipos de tecidos em feridas	20
Figura 2.2 – Cubo unitário de cores RGB.	22
Figura 2.3 – Cubo de cores RGB, representação das cores primárias e suas combinações	22
Figura 2.4 – Representação do plano de coordenadas (a^*,b^*) do método CIELab . .	23
Figura 2.5 – Representação do plano HSV	24
Figura 2.6 – Máscara 3x3 sendo aplicada em uma vizinhança adjacente ao ponto (x, y)	25
Figura 2.7 – Filtragem no domínio espacial	26
Figura 2.8 – Valores de um histograma, onde $L = 256$	27
Figura 2.9 – Exemplo de segmentação por descontinuidade	28
Figura 2.10–Exemplo de segmentação por similaridade	28
Figura 2.11–Detecção de bordas através da variação nos níveis de cinza.	29
Figura 2.12–Detecção de borda utilizando os gradientes x e y do filtro de Prewitt. .	31
Figura 2.13–Detecção de borda utilizando os gradientes x e y do filtro de Sobel. . .	32
Figura 2.14–Exemplo de segmentação por similaridade com escala invertida.	33
Figura 2.15–Segmentação de imagens utilizando o método SLIC	36
Figura 3.1 – Diagrama da metodologia aplicada.	38
Figura 3.2 – Aquisição de imagens conforme requisições estabelecidas pelo protocolo proposto.	39
Figura 3.3 – Scatter das médias de cores de cada segmento no espaço <i>HSV</i>	41
Figura 3.4 – Aplicação de um filtro para remoção do fundo azul presente na imagem.	41
Figura 3.5 – Aplicação de binarização para aquisição do quadrilátero.	42
Figura 3.6 – Aquisição da máscara do quadrilátero.	42
Figura 3.7 – Imagem após retirada do quadrilátero.	43
Figura 3.8 – Segmentação utilizando o método SLIC com valores de $k = 4096$ e $m = 5$.	44
Figura 3.9 – Máscaras correspondentes a cada tipo de tecido.	45
Figura 3.10–Imagens correspondentes a cada tipo de tecido.	46
Figura 3.11–Página inicial do framework.	47
Figura 3.12–Representação da estrutura CRUD.	48
Figura 3.13–Estabelecendo data da aquisição.	49

Figura 3.14—segmentação da imagem inserida.	49
Figura 3.15—segmentação referente ao tipo de tecido.	50
Figura 3.16—Página inicial do framework.	50
Figura 4.1 – Quadro evolutivo do paciente 1	52
Figura 4.2 – Quadro evolutivo do paciente 2	53

Lista de tabelas

Tabela 2.1 – Máscara dos valores obtidos de acordo com o gradiente de Roberts	30
Tabela 2.2 – Máscara dos valores obtidos de acordo com o gradiente de Prewitt	31
Tabela 2.3 – Máscara dos valores obtidos de acordo com o gradiente de Sobel	32
Tabela 4.1 – Resultado referente às amostras	52
Tabela 4.2 – Comparativo da progressão de uma ferida – Paciente 1	53
Tabela 4.3 – Comparativo da progressão de uma ferida – Paciente 2	54
Tabela 4.4 – Erro encontrado de acordo com a diferença das áreas	55
Tabela 4.5 – Resultados obtidos neste trabalho	55
Tabela 4.6 – Resultado obtidos por Marques, [21]	55

Lista de abreviaturas e siglas

CCD (*Charge Coupled Device*)

OMS (Organização Mundial de Saúde)

SLIC (*Simple Linear Iterative Clustering*)

RGB (*Red, Green, Blue*)

CIE (*Commission Internationale de l'Éclairage*)

HSV (*Hue, Saturation, Value*)

DAF (Dimensionamento e Análise de Feridas)

Sumário

1	INTRODUÇÃO	15
1.1	Contextualização	15
1.2	Formulação do problema	15
1.3	Justificativa	16
1.4	Objetivo	17
1.4.1	Objetivo Geral	17
1.4.2	Objetivos Específicos	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	Cicatrização de feridas	18
2.2	Processamento digital de imagens	20
2.2.1	Digitalização	21
2.2.2	Imagem colorida	21
2.2.2.1	Modelo RGB	21
2.2.2.2	Espaço de cores CIELab	23
2.2.2.3	Espaço de cores HSV	24
2.2.3	Filtragem	25
2.2.3.1	Filtragem Espacial	26
2.2.4	Histograma	26
2.3	Segmentação de imagens	27
2.3.1	Detecção de Bordas	28
2.3.2	Limiarização	32
2.3.3	Limiars múltiplos	33
2.4	Simple Linear Iterative Clustering - <i>superpixel</i>	34
2.5	Trabalhos relacionados	37
2.5.1	Segmentação de imagens para tratamento de feridas	37
3	METODOLOGIA	38
3.1	Visão geral do sistema	38
3.2	Aquisição de imagens	39

3.3	Redimensionamento e Filtragem	40
3.3.1	Redimensionamento da imagem	40
3.3.2	Filtragem da imagem	40
3.4	Limiarização e extração de dados presentes no retângulo	41
3.5	Aplicação do algoritmo de segmentação SLIC	43
3.5.1	Segmentação dos diferentes tipos de tecidos	44
3.6	Dimensionamento da ferida	46
3.7	Framework	47
3.7.1	Create, Read, Delete and Update – (CRUD)	48
3.7.2	Quadro Clínico	48
4	RESULTADOS	51
4.1	Análise dos Resultados	51
4.2	Quadro Evolutivo	52
4.2.1	Paciente 1	52
4.2.2	Paciente 2	53
4.3	Validação dos dados obtidos	54
4.4	Comparação com outros trabalhos	55
5	CONCLUSÕES E TRABALHOS FUTUROS	56
	Referências	58
6	ANEXOS	61

1 Introdução

1.1 Contextualização

As feridas são consideradas um problema grave e de abrangência mundial, responsáveis por significativos índices de morbidade e mortalidade. Podem ser definidas como a interrupção da continuidade de um tecido corpóreo, em maior ou em menor extensão, causada por qualquer tipo de trauma físico, químico, mecânico ou desencadeada por uma afecção clínica [1]. Seus sintomas provocam considerável impacto ao paciente, pois causam dor, imobilidade, incapacidade, alterações psicoemocionais relacionadas à autoestima e à auto-imagem, mudanças sociais advindas de hospitalizações e afastamento do convívio social [1]. A assistência aos pacientes com feridas envolve desde questões biofisiológicas até emocionais, devendo ser prestada de maneira integral, o que é possível diante da sistematização da assistência de enfermagem [1].

As feridas podem ser classificadas em agudas, quando o processo de cicatrização ocorre normalmente, dentro de um período pré estabelecido de acordo com sua gravidade. Já as feridas crônicas necessitam de acompanhamento especializado para seu tratamento, pois em maior parte estão associadas a algum tipo de doença pré-existente e ocorrem por complicações presentes no sistema vascular [2].

Otimizar o mecanismo de visualização dos diferentes tecidos em uma lesão pode auxiliar no tratamento, pois traz informações significativas para evitar a proliferação da lesão para além das bordas, bem como comparações sobre as dimensões iniciais e atuais de feridas.

1.2 Formulação do problema

Os tratamentos de feridas que são realizados de forma incorreta podem ocasionar um aumento da lesão, fazendo com que ela aumente pelas bordas da epiderme [3]. Realizado de forma correta, ocasiona a criação de tecido de granulação, fazendo com que novos vasos sanguíneos e tecidos conectivos sejam formados, ocorrendo o processo de epitelização das bordas ao centro da ferida e posteriormente, ocorre o fim da cicatrização

(epitelização).

A maioria dos tratamentos realizados em feridas crônicas são executados por uma equipe, sendo feita a troca do curativo por diferentes integrantes. Desta forma, não há um acompanhamento do estado anterior do paciente, inviabilizando a criação de um quadro evolutivo da lesão. Este fato pode ocasionar no retardo da cicatrização, pois os clínicos não possuem dados suficientes para visualizar a ocorrência de uma disfunção na área lesionada.

Há algum tempo, o tratamento das lesões deixou de ser apenas focado na realização da técnica de curativo, incorporando toda a metodologia da assistência que o enfermeiro presta, com avaliação do estado geral do paciente, exame físico direcionado de acordo com a etiologia da lesão, escolha do tratamento e da cobertura a ser utilizada, além do registro de enfermagem e projeção prognóstica. A enfermagem e outras áreas da saúde vêm buscando conhecimentos relativos à prevenção de danos teciduais e do tratamento e cuidados com feridas que possam melhorar sua práxis neste sentido [4].

Para otimizar o processo de cicatrização de feridas, a criação de uma ferramenta para verificar o quadro evolutivo da ferida é muito importante, uma vez que esta possibilita a visualização dos segmentos de diferentes cores na região lesionada. Realizar o tratamento utilizando o método de segmentação de imagens traz dados que possibilitam o diagnóstico de problemas ocorridos durante o tratamento.

1.3 Justificativa

A ferida enfraquece a região afetada, podendo, em muitas das vezes, incapacitar o afetado de desenvolver atividades do cotidiano. Atinge a população, tanto mulheres quanto homens, possuindo custos elevados para a realização do tratamento de feridas com baixo índice evolutivo de cicatrização.

Quantificar a distribuição de cores em feridas por técnicas de processamento digital de imagens pode ajudar na caracterização e análise de processos patológicos bem como respostas positivas ao tratamento, melhorando o processo de cicatrização [5].

Portanto, buscando melhor resultado na realização do tratamento de feridas, a utilização de ferramentas computacionais podem auxiliar nos tratamentos de feridas.

1.4 Objetivo

O trabalho proposto, tem como objetivo realizar o mapeamento da área de uma ferida, por meio da técnica SLIC (tradução, do inglês, Agrupamento Iterativo Linear Simples) - *superpixel*, segmentando áreas da região preterida, com o objetivo de acompanhar e auxiliar a recuperação do processo de cicatrização da ferida.

1.4.1 Objetivo Geral

Desenvolver uma ferramenta capaz de dimensionar feridas e segmentar a área lesionada em pequenas regiões diferenciadas por cores, de forma a auxiliar em trabalhos posteriores.

1.4.2 Objetivos Específicos

1. Utilizar algoritmos de segmentação SLIC para separar regiões de acordo com a coloração do tecido (granulado, fibrinoso e necrosado), destacando os locais mais importantes para a progressão do tratamento.
2. Levantar dados durante o processo de cicatrização de feridas, tais como as dimensões da região a ser tratada;
3. Levantar um banco de dados com o intuito de comparar feridas ao decorrer do tempo;
4. Levantar uma plataforma web com interface para usuários.

2 Fundamentação teórica

2.1 Cicatrização de feridas

A cicatrização consiste no fenômeno dinâmico envolvendo diversas células epiteliais, inflamatórias, plaquetas e fibroblastos que trabalham em prol da incolumidade dos tecidos. A produção de um tecido novo e a utilização de matéria orgânica nesse processo dependerá do nível de contaminação da ferida, local da ferida, profundidade e idade do indivíduo. O processo de recuperação do tecido lesionado, desencadeado pelo corpo humano, geram a formação e alguns tipos de tecidos que podem ser observadas na região lesionada.

Segundo Mandelbaum, Di Santis & Mandelbaum as feridas podem ser classificadas em feridas de espessura parcial ou de espessura total [6]. A ferida de espessura parcial (derme incompleta) ocorre após muitos procedimentos dermatológicos como a dermoabrasão, *resurfacing* por laser ou *peeling*, e também pode ser causada por traumatismos. A reparação faz-se pela reepitelização dos anexos epiteliais ou epitélio derivado da pele adjacente não acometida. Como resultado final tem-se uma cicatriz praticamente imperceptível. Já as feridas de espessura total (derme completa ou estendida ao tecido celular subcutâneo) necessitam da formação de um novo tecido, o tecido de granulação; a epitelização, base da cicatrização nas feridas de espessura parcial, acontece apenas nas margens da ferida. Nesse caso, a cicatriz é totalmente perceptível e, muitas vezes pronunciada.

O processo de cicatrização pode ser dividido em fases, sendo elas:

- Coagulação;
- Inflamação;
- Proliferação;
- Contração da ferida;
- Remodelação.

A coagulação ocorre imediatamente após a formação da ferida, liberando plaquetas e uma diversidade de produtos cuja finalidade será unir as bordas da ferida, além de desencadear os demais processos.

A fase inflamatória está diretamente ligada à fase de coagulação e será uma reação do corpo à ferida ocasionada. Pouco tempo após ocorrer a lesão, serão liberados macrófagos, linfócitos e leucócitos, que terão papel fundamental nessa fase. Nesse processo há a fagocitose das bactérias e remoção dos corpos estranhos presentes e a formação de uma espécie de cola composta por colágeno, fibrina e outras células originando uma base para a matriz celular.

Por sua vez, na fase de proliferação ocorrem a reepitelização, onde há a reprodução de vasos sanguíneos que geram um processo de reconstrução, a fibroplasia, responsável pela formação do tecido de granulação, e a angiogênese, responsável pela nutrição da cicatrização. Nesta fase há o fechamento da ferida.

A contração da ferida consiste no movimento centrípeto das bordas. E a remodelação, última fase, e é responsável pelo fortalecimento da tensão e diminuição da cicatriz.

O tipo de tecido gerado durante o tratamento indica as condições de recuperação de uma região lesionada, pois, de acordo com o tecido, é possível saber se há progresso ou não na região tratada. Dentre os tipos de tecidos, para realizar uma análise de feridas é necessário observar os tecidos de granulação, fibrina e necrose.

Dentre os tipos de tecidos, para realizar uma análise da recuperação das feridas é necessário observar o desenvolvimento dos tecidos pelo processo de granulação e necrose. A granulação, início do processo de regeneração, ocorre devido a pequenos vasos que são formados sobre a região lesionada junto a tecidos conectivos para preencher a parte danificada do tecido. Um certo tom de vermelho pode ser observado na ferida. O vermelho mais vivo indica um tecido saudável, mais vascularizado de recuperação mais rápida, o vermelho mais claro indica uma baixa vascularização, que gera uma recuperação mais lenta [7].

O tecido de necrose corresponde ao tecido morto, representa as células que sofreram lesões irreversíveis, geralmente acompanhada materiais fibrosos e pus. A formação de tecido necrosado não é desejável durante a cicatrização, o procedimento médico indicado neste instante é limpeza da área e remoção deste tecido. Podemos observar nesta fase uma

coloração que varia de um cinza mais escuro, a marrom ou preto.

Podemos observar também no início do processo de cicatrização, ou após a remoção do tecido necrosado, um líquido de coloração amarelada clara/esbranquiçada, gerado pelo processo de coagulação do sistema imunológico e pela fibrina.

A fibrina é uma proteína insolúvel formada a partir do fibrinogênio e a ação proteolítica da trombina, ela adere a superfície necrosada, para recobrir o tecido lesionado para estancar o vazamento de sangue e proteger contra infecções, esta coloração amarelada, indica um bom funcionamento do sistema imunológico [2].

Podemos visualizar abaixo, na Figura 2.1 os diferentes tipos de tecidos e suas colorações.



Figura 2.1 – Representação dos diferentes tipos de tecidos em feridas.

Fonte: Adaptado de [8]

O processamento digital de imagens é um método muito utilizado para separar regiões por cores, sendo possível realizar diversas outras manipulações em imagens, possibilitando a classificação dos tipos de tecidos de uma ferida.

2.2 Processamento digital de imagens

Uma imagem pode ser definida como uma função bidimensional, $f(x, y)$, na qual x e y são coordenadas espaciais, e a amplitude de f em qualquer par de coordenadas (x, y) é chamada de intensidade ou nível de cinza da imagem naquele ponto. Quando os valores de x , de y e da amplitude são finitos, ou seja, quantidades discretas, chama-se a imagem de imagem digital [9].

2.2.1 Digitalização

No domínio espacial os pares (x, y) representam os pontos consecutivos de uma linha de uma imagem, o *pixel* (do inglês, picture element), onde, por convenção: $x = [0, 1, 2, \dots, M]$ e $y = [0, 1, 2, \dots, N]$. Dessa forma, o valor digital da imagem na origem é representado por $f(0, 0)$ e a segunda coordenada ao longo da linha é descrita por $f(0, 1)$ e assim sucessivamente [10]. O valor de f nos pontos (x, y) equivalem ao nível de cinza naquele ponto. Desta forma é possível obter uma relação matricial $M \times N$, onde cada ponto da matriz é denotada como um *pixel* com seu argumento equivalente ao valor de intensidade do ponto, ou seja,

$$\mathbf{f}(\mathbf{x}, \mathbf{y}) = \begin{bmatrix} f(0, 0) & f(0, 1) & f(0, 2) & \dots & f(0, N-1) \\ f(1, 0) & f(1, 1) & f(1, 2) & \dots & f(1, N-1) \\ f(2, 0) & f(2, 1) & f(2, 2) & \dots & f(2, N-1) \\ \vdots & \vdots & \vdots & & \vdots \\ f(M-1, 0) & f(M-1, 1) & f(M-1, 2) & \dots & f(M-1, N-1) \end{bmatrix}. \quad (2.1)$$

A capacidade de detalhes que uma figura é ligada a intensidade que ela possui. Quanto maior a quantização, maiores são os níveis de cinza, fazendo com que cada *pixel* tenha um maior grau de liberdade em relação a sua vizinhança. Os níveis de cinzas são definidos por uma variável $L : \{\in \mathbb{Z}_+\}$ que por algumas considerações de hardware no processo de armazenamento e quantização, o número de níveis costuma ser definido por uma potência de 2 [9], portanto $L = 2^k$, onde $k : \{\in \mathbb{Z}_+\} = [0, 1, 2, \dots]$

2.2.2 Imagem colorida

Uma imagem pode ser expressa por meio de um conjunto de pontos coloridos, *pixel*, onde qualquer cor pode ser expressa como uma combinação das cores primárias vermelha, verde e azul. Para obter a especificação das cores, de forma padronizada, alguns modelos de cores foram criados, possibilitando a implementação em hardware ou aplicações que envolvem manipulação de cores [9].

2.2.2.1 Modelo RGB

O modelo RGB é descrito por meio de um vetor tridimensional $[RGB]$, normalizado, e representado por um cubo unitário, ou seja, possui vetores unitários com valores

dentro do intervalo $[0, 1]$. Conforme ilustrado na Figura 2.2, cada vetor unitário representa uma cor primária no espaço de coordenadas cartesianas, sendo que as demais cores são formadas por meio da combinação destes elementos.

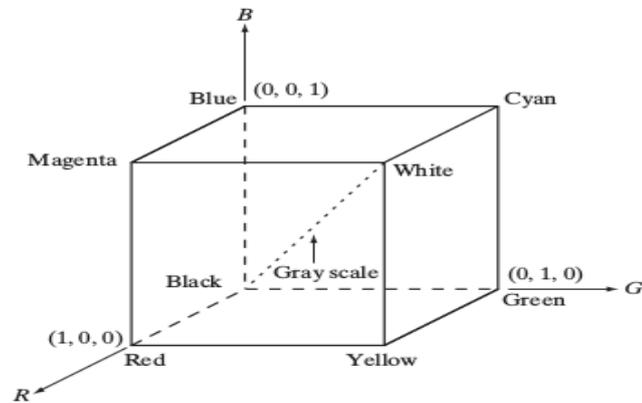


Figura 2.2 – Cubo unitário de cores RGB.
Fonte: Adaptado de [9]

No formato digital, as imagens são representadas por três componentes de imagens, uma para cada cor primária. Normalmente representada por 8 bits, em formato decimal ou hexadecimal, expressando a profundidade de cada pixel ou quantidade de níveis. Portanto, para expressar a cor branca, será necessário produzir um vetor com os seguintes parâmetros $[255\ 255\ 255]$, decimal, ou $[FF\ FF\ FF]$, hexadecimal. A Figura 2.3 representa o plano de coordenadas cartesianas com a combinação das componentes de cores primárias.



Figura 2.3 – Cubo de cores RGB, representação das cores primárias e suas combinações
Fonte: Adaptado de [9]

2.2.2.2 Espaço de cores CIELab

A comissão internacional de iluminação (CIE, do francês, International Commission on Illumination) desenvolveu o método CIELab que promove a organização de cores de acordo com a relação numérica existente entre os tons vermelho, verde, azul e amarelo, onde a escala de cinza é definida pela luminância presente na imagem [11].

O método constitui em expressar as cores por meio da tonalidade, luminosidade e saturação presentes em um plano de coordenadas. De acordo com a escala presente no espaço de coordenadas, é possível expressar com precisão o conjunto de cores presentes no espectro visível.

A cor de um pixel definida no espaço de cores CIELab pode ser expressa por meio de uma distância d_c , sendo definida de acordo com os parâmetros $[l \ a \ b]^T$, onde qualquer cor pode ser representada de acordo com a Equação 2.2

$$d_c = \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2}. \quad (2.2)$$

A Figura 2.4 apresenta o espaço de coordenadas do método CIELab, onde a localização de qualquer cor no espaço pode ser encontrada por meio dos parâmetros $L^* a^* b^*$, onde: (1) L^* indica a luminosidade presente na figura; (2) a^* coordenada que expressa a coloração vermelha diante de índices positivos e verde para diante de valores negativos; (3) b^* coordenada que expressa a coloração amarela diante de índices positivos e azul para diante de valores negativos.

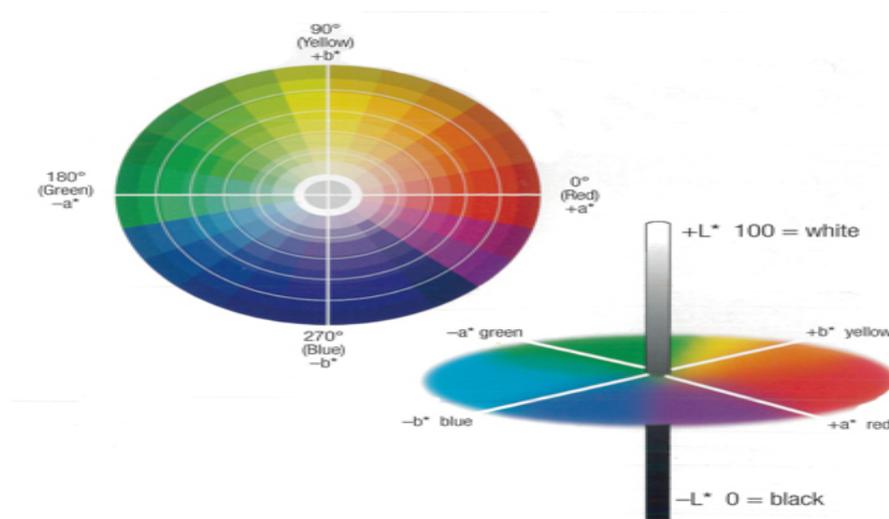


Figura 2.4 – Representação do plano de coordenadas (a^*, b^*) do método CIELab

Fonte: Adaptado de [12]

2.2.2.3 Espaço de cores HSV

O HSV surgiu em 1970 quando pesquisadores na área de computação gráfica buscavam representar numericamente as propriedades das cores, criando um modelo que se aproxima com os atributos de cores perceptíveis à visão humana. Desta forma, foram estabelecidos 3 atributos para representar este espaço de cor, sendo eles matiz, saturação e valor [13], onde:

1. Matiz – É o atributo responsável pela sensação visual de cores, onde é possível perceber cores como o vermelho, verde, azul ou combinações entre as cores.
2. Saturação – Representa a coloração de um estímulo de acordo com a pureza da cor, fazendo com que valores baixos se aproximem do cinza e valores altos da própria matiz.
3. Valor – Responsável por regular o brilho da imagem, valores baixos se aproximam do preto, enquanto valores mais altos determinam a cor por meio da relação matiz x saturação.

A Figura 2.5 demonstra como funciona a relação entre os atributos existentes no plano de cores HSV.

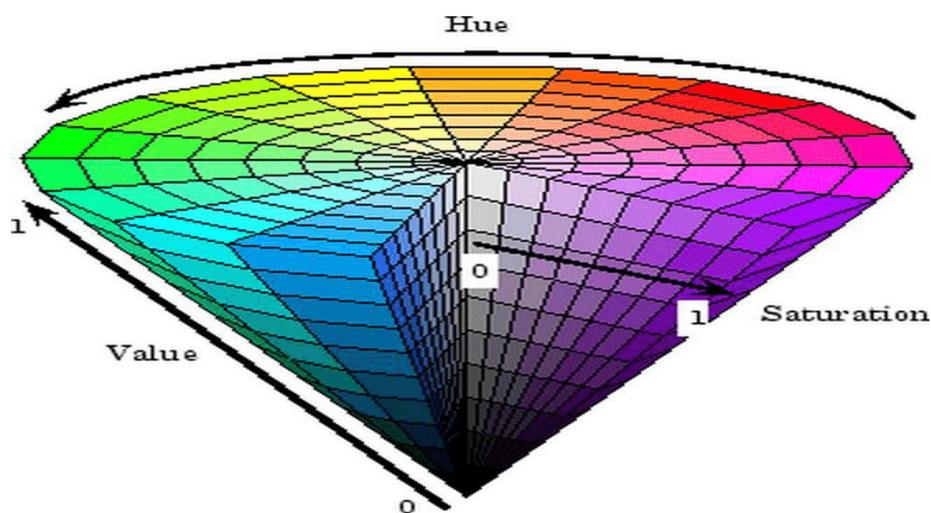


Figura 2.5 – Representação do plano HSV.
Fonte: Adaptado de [14]

2.2.3 Filtragem

Algumas atividades de processamento digital de imagens podem ser realizadas no domínio espacial ou de frequência, sendo que alguns processos são mais simples de serem realizados no domínio espacial. Sendo assim, podemos expressar processos do domínio espacial de acordo com a seguinte equação

$$g(x, y) = T[f(x, y)], \tag{2.3}$$

onde $f(x, y)$ é a imagem de entrada, $g(x, y)$ é a imagem de saída, e T é um operador em f definido em uma vizinhança do ponto (x, y) [9].

Normalmente a vizinhança de um *pixel* é definida em formatos retangulares, pois define um melhor parâmetro de simetria com o *pixel* central [9]. Desta forma, operações podem ser geradas de acordo com o comportamento que atua dentro do conjunto de *pixels* em uma região, conforme apresentado na Figura 2.6.

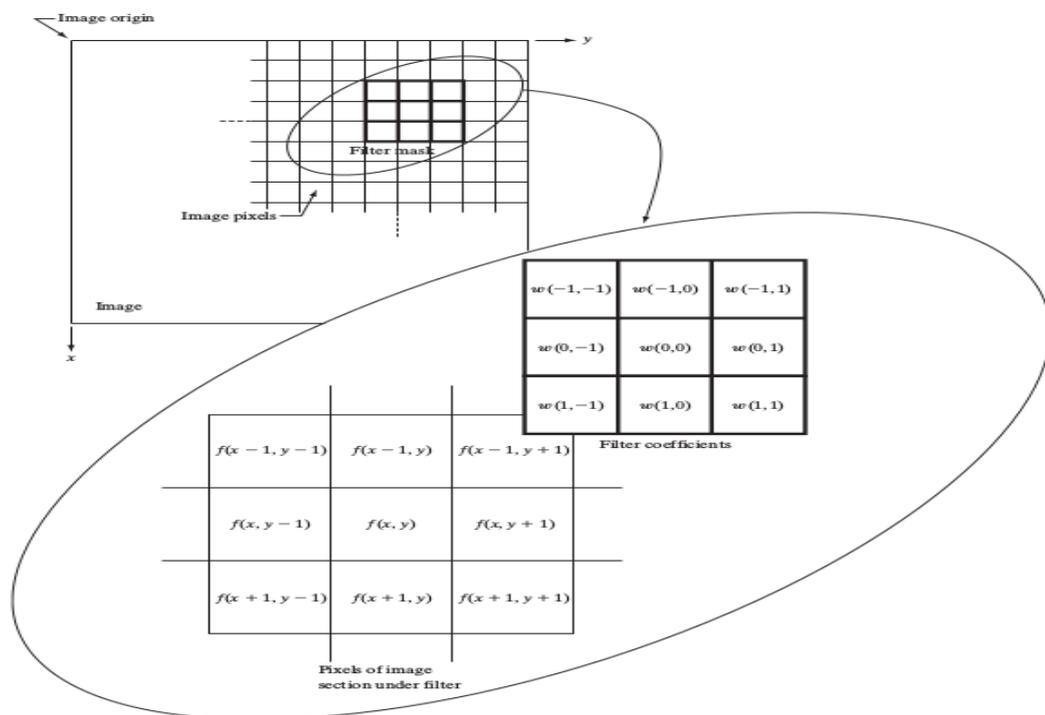


Figura 2.6 – Máscara 3x3 sendo aplicada em uma vizinhança adjacente ao ponto (x, y)
Adaptado de [9]

2.2.3.1 Filtragem Espacial

A filtragem espacial ocorre quando uma imagem é filtrada de acordo com a sua vizinhança. Em uma matriz cada posição é preenchida por um valor de intensidade, onde esse espaço é chamado de *pixel*. O processo de filtragem, através de uma máscara, cria um novo *pixel* com coordenadas iguais ao centro da vizinhança, gerando uma imagem $g(x, y)$ a medida em que todos os pares (x, y) são filtrados, de acordo com a Figura 2.7.

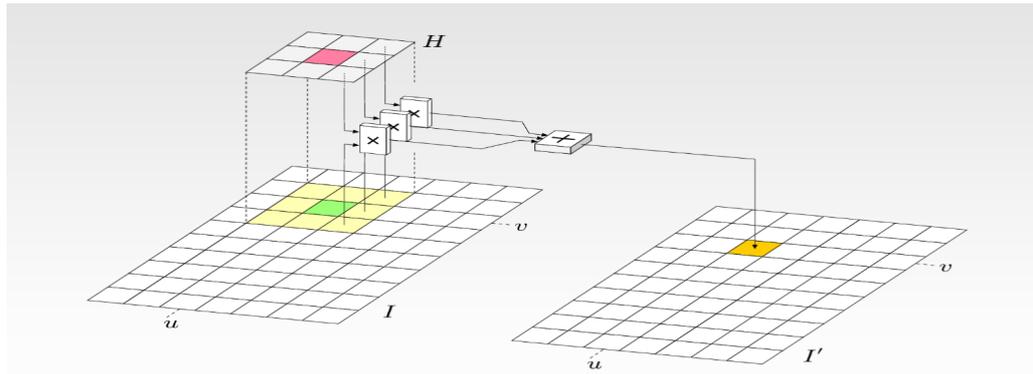


Figura 2.7 – Filtragem no domínio espacial.

Fonte: Adaptado de [15]

É possível descrever o comportamento de um filtro linear espacial, relacionando-o com a imagem de entrada $f(x, y)$ de acordo com a vizinhança. O valor do *pixel* de saída é igual a soma dos coeficientes do filtro, $w(s, t)$ com os *pixels* relativos aos pares englobados,

$$g(x, y) = w(-1, -1)f(x - 1, y - 1) + w(-1, 0)f(x - 1, y) \\ + \dots + w(0, 0)f(x, y) + \dots + w(1, 1)f(x + 1, y + 1)$$

portanto, $g(x, y)$ pode ser escrito como

$$g(x, y) = \sum_{s=-1}^1 \sum_{t=-1}^1 w(s, t)f(x + s, y + t). \quad (2.4)$$

2.2.4 Histograma

O histograma é uma representação gráfica dos níveis de intensidade dentro de um intervalo L, indicando o percentual de *pixels* da imagem que apresentam um determinado nível de cinza [10]. Um conjunto de elementos é responsável por levantar uma probabilidade do número de *pixels* que possuem o mesmo nível de cinza, criando uma estimativa

sobre a quantidade de tons de cinza que existem na imagem. Cada elemento do conjunto é calculado por

$$P_r(r_k) = \frac{n_k}{MN}, \quad (2.5)$$

onde

$P_k(r_k)$ = probabilidade do k-ésimo valor de intensidade;

n_k = número de *pixels* da imagem com intensidade em r_k ;

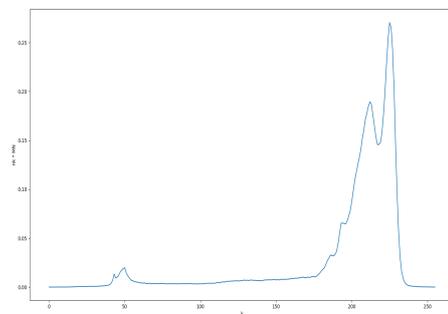
MN = número total de *pixels* na imagem;

$k = 0, 1, \dots, L-1$, onde L equivale a quantidade de níveis.

De acordo com a Figura 2.8, o eixo horizontal do histograma representa aos valores de intensidade e o eixo vertical aos valores de $p(r_k)$. Desta forma, é possível destacar diferenças entre de tonalidades em imagens, como a concentração de níveis de cinza em imagens mais escuras, claras, de baixo contraste ou alto contraste.



(a) Imagem original. Fonte: Adaptado de [16]



(b) Histograma

Figura 2.8 – Valores de um histograma, onde $L = 256$

2.3 Segmentação de imagens

O princípio fundamental da segmentação é dividir uma imagem digital em regiões, conjunto de *pixels*, com o intuito de facilitar a análise local. Geralmente são baseadas em duas categorias básicas relacionadas às propriedades dos valores de intensidade: descontinuidade e similaridade [9].

A descontinuidade refere-se à diferenças significativas entre os níveis de cinza nas fronteiras das regiões, possibilitando a detecção dos limites do objeto com base na diferença de intensidade. Aplicações como detecção de bordas são amplamente utilizados nesse método, conforme ilustrado na Figura 2.9.

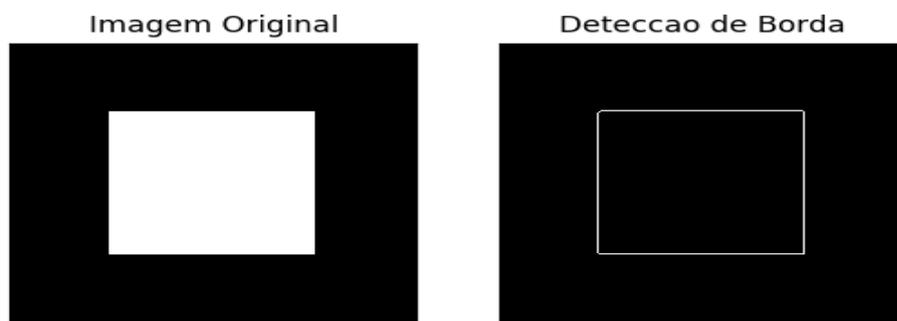


Figura 2.9 – Exemplo de segmentação por descontinuidade

A similaridade refere-se a separação por regiões em comum de acordo com dados pré definidos. Separação de regiões com tons de cinza em uma imagem são aplicações do método de similaridade. Na Figura 2.10 é possível ver a relação entre as diversas áreas que possuem a mesma intensidade, separas por uma região que contém todos os *pixels* com o mesmo nível de cinza.



Figura 2.10 – Exemplo de segmentação por similaridade.
Fonte: Adaptado de [9]

2.3.1 Detecção de Bordas

Técnicas de detecção de bordas geralmente são usadas para detectar mudanças nas escala de cinza de uma imagem. Detectar descontinuidades consecutivas em escala de cinza de uma imagem é uma abordagem muito importante dentro das técnicas de segmentação .

A detecção de borda ocorre quando há uma mudança nos níveis de cinza ao longo de uma linha, onde essa mudança pode ser detectada por três eventos. Caso haja uma mudança quase que instantânea dos níveis de cinza, dizemos que ocorreu uma detecção de borda por degrau, representado na Figura 2.11(a). Nas mudanças de escala que ocorrem de forma gradativa entre dois níveis distantes de cinza, ocorre uma detecção de borda por rampa, conforme apresentado na Figura 2.11(b). Nos casos em que existe uma variação de intensidade de um nível qualquer que possui um valor de máximo ou mínimo e retorna ao seu valor, ocorre uma detecção de borda em formato de telhado, representado pela Figura 2.11(c), onde a espessura do comprimento da borda expressa a espessura de uma linha.

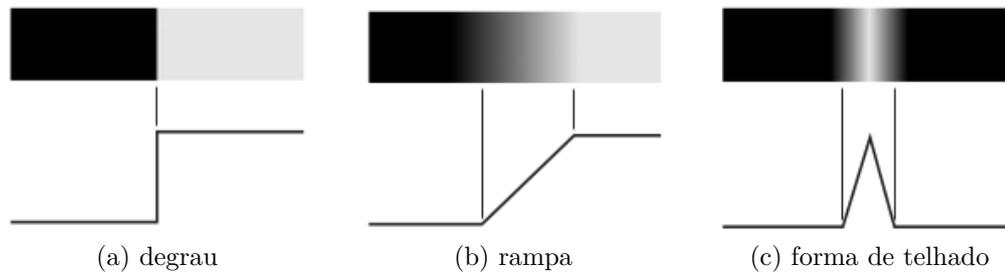


Figura 2.11 – Detecção de bordas através da variação nos níveis de cinza.
Fonte: Adaptado de [9]

O gradiente é capaz de expressar a intensidade e direção da borda em um ponto qualquer $f(x, y)$ de uma imagem. Desta forma, acaba sendo uma ferramenta muito útil para a detecção de bordas. O gradiente pode ser expressado pela seguinte equação

$$\nabla f = \text{grad}(f) = \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix}, \quad (2.6)$$

de forma que a magnitude e o ângulo do gradiente podem ser calculados utilizando a Equação 2.7 e a Equação 2.8, respectivamente

$$M(x, y) = \sqrt{g_x^2 + g_y^2}, \quad (2.7)$$

$$\theta(x, y) = \text{tg}^{-1} \begin{bmatrix} g_y \\ g_x \end{bmatrix}. \quad (2.8)$$

Conforme expresso na Equação 2.6, o gradiente tem uma derivada parcial em x e outra em y , responsáveis por descreverem a mudança nos níveis de cinza de uma imagem. No espaço digital, as derivadas possuem comportamento diferentes ao do domínio contínuo. Portanto, é necessário expandir por séries de Taylor para encontrar uma equivalência das derivadas no espaço digital, onde as derivadas são aproximadas pela seguinte função

$$\frac{\partial f}{\partial x} = f'(x) = f(x + 1) - f(x), \quad (2.9)$$

desta forma, podemos utilizar a Equação 2.9, para obtendo as seguintes expressões do gradiente

$$g_x = \frac{\partial f(x, y)}{\partial x} = f(x + 1, y) - f(x, y), \quad (2.10)$$

$$g_y = \frac{\partial f(x, y)}{\partial y} = f(x, y + 1) - f(x, y). \quad (2.11)$$

Os valores de gradiente podem filtrar os valores de qualquer imagem em 1 dimensão (1-D). Porém, pode ser implementado em 2 dimensões (2-D), conforme proposto por Roberts. Portanto, de acordo com a Tabela 2.1 teremos as seguintes máscaras.

Tabela 2.1 – Máscara dos valores obtidos de acordo com o gradiente de Roberts

(a)	(b)								
<table border="1" style="border-collapse: collapse; width: 100%; height: 100%;"> <tr> <td style="padding: 5px;">-1</td> <td style="padding: 5px;">0</td> </tr> <tr> <td style="padding: 5px;">0</td> <td style="padding: 5px;">1</td> </tr> </table>	-1	0	0	1	<table border="1" style="border-collapse: collapse; width: 100%; height: 100%;"> <tr> <td style="padding: 5px;">0</td> <td style="padding: 5px;">-1</td> </tr> <tr> <td style="padding: 5px;">1</td> <td style="padding: 5px;">0</td> </tr> </table>	0	-1	1	0
-1	0								
0	1								
0	-1								
1	0								

O filtro proposto por Roberts é descentralizado, fazendo com que o método de filtragem não seja muito interessante em relação aos filtros simétricos. Desta forma, Prewitt formulou as seguintes máscaras.

Para ilustrar o exemplo de detecção de bordas, utilizaremos o filtro de Prewitt por possuir simetria com um ponto qualquer (x, y) do plano espacial. O filtro irá realizar uma convolução com todos os *pixels*, gerando uma imagem $g(x, y)$ conforme apresentado na Figura 2.12.

Tabela 2.2 – Máscara dos valores obtidos de acordo com o gradiente de Prewitt

(a)		
-1	-1	-1
0	0	0
1	1	1

(b)		
-1	0	1
-1	0	1
-1	0	1

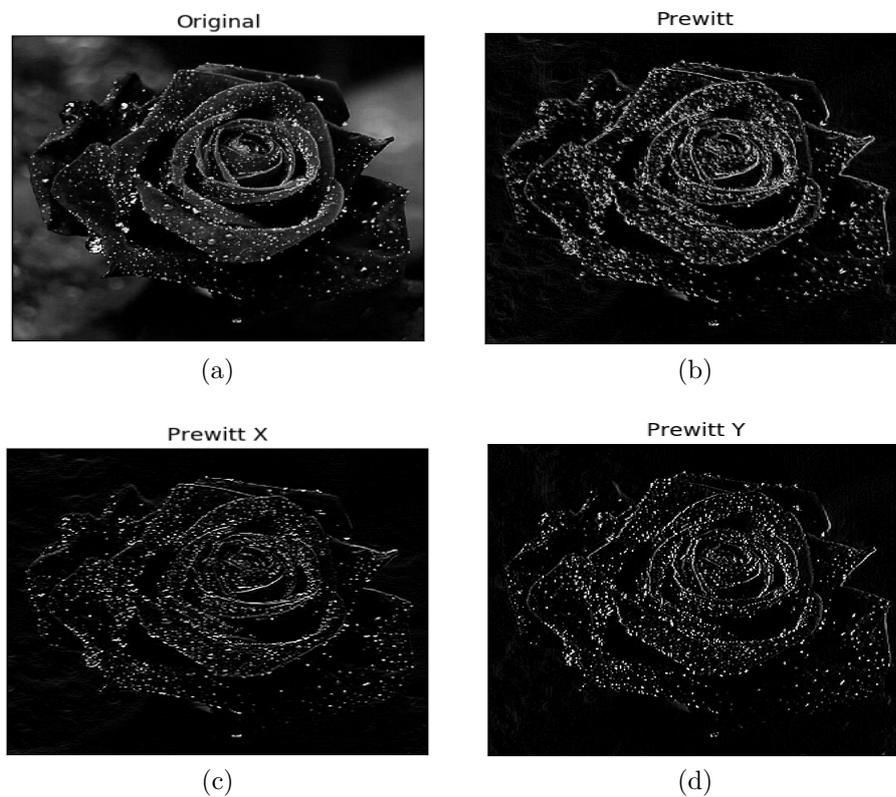


Figura 2.12 – Detecção de borda utilizando os gradientes x e y do filtro de Prewitt.

Fonte: Adaptado de [17]

As derivadas são funções sensíveis a qualquer tipo de transição, portanto um sistema com ruído será mais difícil de filtrar. Para melhorar os resultados de um sistema com ruído, foi proposto por Sobel uma implementação matemática que realiza uma suavização da imagem, redução de ruído, possibilitando a criação de uma máscara com melhores resultados no processo de filtragem, conforme apresentado na Tabela 2.3.

De acordo com a Figura 2.13, é possível observar uma melhoria em relação ao filtro de Prewitt na segmentação de bordas e pontos, sendo perceptível o aumento no contraste, pois a imagem passa por uma suavização durante a aplicação do filtro de Sobel.

Tabela 2.3 – Máscara dos valores obtidos de acordo com o gradiente de Sobel

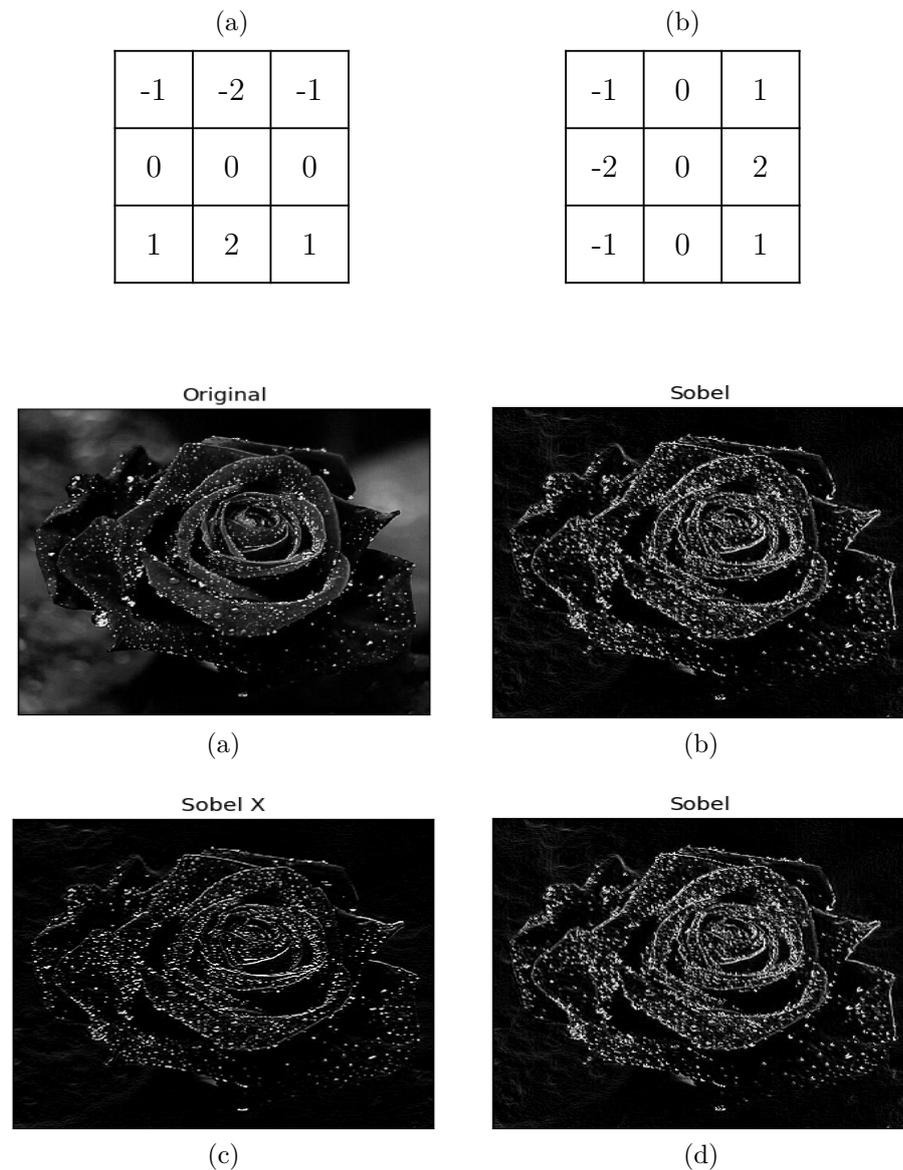


Figura 2.13 – Detecção de borda utilizando os gradientes x e y do filtro de Sobel.

Fonte: Adaptado de [17]

2.3.2 Limiarização

A limiarização é fundamentada na análise por similaridade, onde a divisão de regiões é formada de acordo com os valores de níveis de cinza em cada *pixel*. Tem como função extrair objetos de interesse de acordo com um limiar definido em T que separa os agrupamentos de cinza. Normalmente, o valor do limiar é definido com base no histograma. Desta forma, em um ponto qualquer, onde $f(x, y) > T$ o objeto é identificado, representado pela expressão *ponto do objeto*, e para os valores de um ponto qualquer, onde $f(x, y) < T$ o plano de fundo é identificado, representado pela expressão *ponto de fundo* [9]. De acordo

com a Equação 2.12, a imagem de saída $g(x, y)$ é dada por

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T, \\ 0 & \text{se } f(x, y) < T. \end{cases} \quad (2.12)$$

De acordo com o histograma definido na Figura 2.14 se o limiar T for definido com o valor $T = 150$, teremos todos os valores $f(x, y) < 150$ convertidos para 0 e os valores $f(x, y) > 150$ serão convertidos para 1 fazendo com que seja possível diferenciar o objeto do fundo da imagem. Este método é conhecido como *thresholding*.

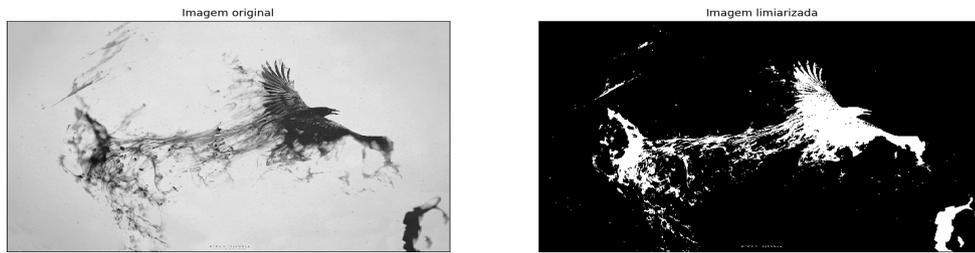


Figura 2.14 – Exemplo de segmentação por similaridade com escala invertida.

Fonte: Adaptado de [16]

2.3.3 Limiares múltiplos

Tem como objetivo determinar valores ótimos limiares por meio do histograma de uma imagem, com o objetivo de iterar todos os valores possíveis de uma imagem digital $M \times N$ com L valores distintos de níveis de cinza, maximizando o cálculo da variância intraclasse da imagem [9]. Para determinar a variância em K classes, onde cada classe é representada por C_1, C_2, \dots, C_K utilizamos a Equação 2.13

$$\sigma_B^2 = \sum_{k=1}^K P_k (m_k - m_G)^2, \quad (2.13)$$

onde

$$m_G = \sum_{i=0}^{L-1} i p_i, \quad (2.14)$$

$$P_k = \sum_{i \in C_k} p_i, \quad (2.15)$$

$$m_k = \frac{1}{P_k} \sum_{i \in C_k} i p_i. \quad (2.16)$$

Portanto, para determinar os valores de limiares ótimos $[k_1^*, k_2^*, \dots, k_{K-1}]$ para as K classes, é necessário encontrar os valores máximos presentes na equação 2.13

$$\sigma_B^2(k_1^*, k_2^*, \dots, k_{K-1}^*) = \max_{0 < k_1 < k_2 < \dots < k_{K-1} < L-1} \sigma_B^2(k_1, k_2, \dots, k_{K-1}). \quad (2.17)$$

Um processo multi-limiar com 3 classes realiza a segmentação de 3 regiões, onde dois limiares k_1 e k_2 são definidos de acordo com a Equação 2.17, fazendo com que as regiões de uma imagem possam ser definidas pela seguinte expressão

$$g(x, y) = \begin{cases} a & \text{se } f(x, y) \leq k_1^*, \\ b & \text{se } k_1^* < f(x, y) \leq k_2^*, \\ c & \text{se } f(x, y) > k_2^*. \end{cases} \quad (2.18)$$

2.4 Simple Linear Iterative Clustering - *superpixel*

Superpixel é uma técnica de segmentação por similaridade formado por um conjunto de *pixels* em regiões que possuem semelhança na escala de cores. Desta forma, a segmentação por *superpixel* proporciona a divisão de uma imagem em centenas de regiões realizando uma redução de *pixels*, possibilitando uma melhora na análise da imagem [18].

Algoritmos de *superpixel* buscam por redundâncias nas imagens, fornecem um parâmetro conveniente a partir do qual seja possível calcular os recursos da imagem, e reduz consideravelmente a complexidade de tarefas no processamento digital de imagens [19]. Promovem aplicações muito úteis em estimativa de densidade, segmentação de imagem, estimativa do modelo corporal e localização de objetos. Dentre os algoritmos existentes, destacamos o *Simple Linear Iterative Clustering* (SLIC) por possuir eficiência diante dos métodos propostos pelo estado da arte [20].

De acordo com Achanta e Shanji [20], SLIC é um método de simples implementação e aplicação, sendo desejado apenas um parâmetro k para determinar o número de

superpixels. Experimentos armazenados no banco de dados de Berkeley mostram que o método SLIC é mais eficiente que os demais métodos existentes, produzindo segmentação com qualidade melhor ou similar nas fronteiras, retornando baixa margem de erro [20]. É um método baseado no algoritmo *K-means*, reduzindo o limite do espaço de buscas para regiões proporcionais ao tamanho do *superpixel*, onde o tamanho e compactação de cada *superpixel* são definidos de acordo com a cor e proximidade espacial dos *pixels*. O método SLIC pode ser descrito em três passos [18]:

1. Uma imagem de entrada formada por um conjunto N de *pixels* é dividida em k regiões, de dimensão $S \times S$, definidas por $S = \sqrt{\frac{N}{k}}$. Cada *superpixel* é definido por um centroide $C_i = [L_i, a_i, b_i, x_i, y_i]^T$, onde L , a e b são os valores médios dos três componentes do modelo CIELab, conforme explicado na seção 2.2.2.2. Já x_i e y_i são as coordenadas do *superpixel* i ;
2. Em cada iteração do algoritmo, cada *pixel* j da imagem é associado com o centroide do *superpixel* mais próximo, dado que a área de busca de cada *pixel* é associada ao espaço $2S \times 2S$ ao seu redor do centroide C_i . Em seguida, novos centroides são calculados como uma média do vetor C_i , considerando todos os pontos do *superpixel* i . Este processo é executado através distância D entre a centroide e cada *pixel* dentro da do espaço $2S \times 2S$, onde D é definida de acordo com a cor do *pixel* e a distância entre o ponto o *pixel* j e o centroide.

A cor de um *pixel* é definida no espaço de cores CIElab, onde qualquer cor pode ser escrita de acordo com os parâmetros, fazendo com que a distância entre cores de *pixel* seja expressa em função da Equação 2.2.

A distância entre o ponto e o centroide pode ser definida por meio do plano espaço $2S \times 2S$ ao redor do *superpixel*, representado pela Equação 2.19

$$d_s = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2}. \quad (2.19)$$

Portando, a distância D pode ser definida de acordo com a Equação 2.20 sendo necessário um parâmetro de normalização m para destacar o resultado obtido na

distância espacial

$$D = \sqrt{d_c^2 + \left(\frac{d_s}{S}\right)^2 m^2}. \quad (2.20)$$

O parâmetro m deve ser ajustado entre os valores $[1, 40]$. Para valores altos, a ênfase é no plano espacial, fazendo com que os *superpixels* sejam mais compactados. Já para valores baixos, os *superpixels* aderem-se mais as bordas, porém as regiões são formadas em formatos irregulares.

3. Por fim, após o término das iterações, podem surgir grupos isolados de *pixels* remanescentes, que não foram associados a nenhum *superpixel*. Estes grupos devem ser associados ao maior *superpixel* vizinho.

A Figura 2.15 representa o método de segmentação SLIC em uma imagem com valores de $k = 256$ e $k = 512$.



(a) 256 segmentos



(b) 512 segmentos

Figura 2.15 – Segmentação de imagens utilizando o método SLIC

2.5 Trabalhos relacionados

Alguns métodos utilizados neste trabalho apresentam fundamentos na seguinte pesquisa.

2.5.1 Segmentação de imagens para tratamento de feridas

Marques [21], em seu trabalho de conclusão de curso, utilizou o algoritmo *k-means* em conjunto com o espaço de cores YCbCr para segmentação de imagens coloridas, com o intuito de realizar a classificação dos tipos de úlceras.

O protocolo de imagem é formado para a realização do dimensionamento, de forma a diminuir o ruído presente na imagem. Um rótulo com dimensões conhecidas deve englobar a área de captura da câmera, este passo é essencial para registrar as medidas da região de interesse, pois as dimensões do são relativas e variam de acordo com a distância focalizada pelo aparelho de captura. Para realização do processamento digital de imagens, o protocolo requer as seguintes especificações; (1) a imagem não deve possuir sombras, portanto fonte de luz deve ser bem focalizada para evitar que tal comportamento ocorra; (2) cores equivalentes fora da região de interesse devem ser evitadas, pois será reconhecida pelo método de segmentação aplicado; (3) o flash deve ser desativado para evitar a produção de valores falsos; (4) a imagem deve ser formada de forma que o plano da câmera deve ser o mais paralelo possível de acordo com o plano da ferida.

3 Metodologia

3.1 Visão geral do sistema

Este trabalho se baseia na utilização do método de segmentação SLIC para extração de um conjunto características expressos por meio da coloração dos tecidos contidos em uma região lesionada, bem como o dimensionamento da região afetada. O diagrama a seguir mostra a divisão dos processos presentes na metodologia do trabalho.

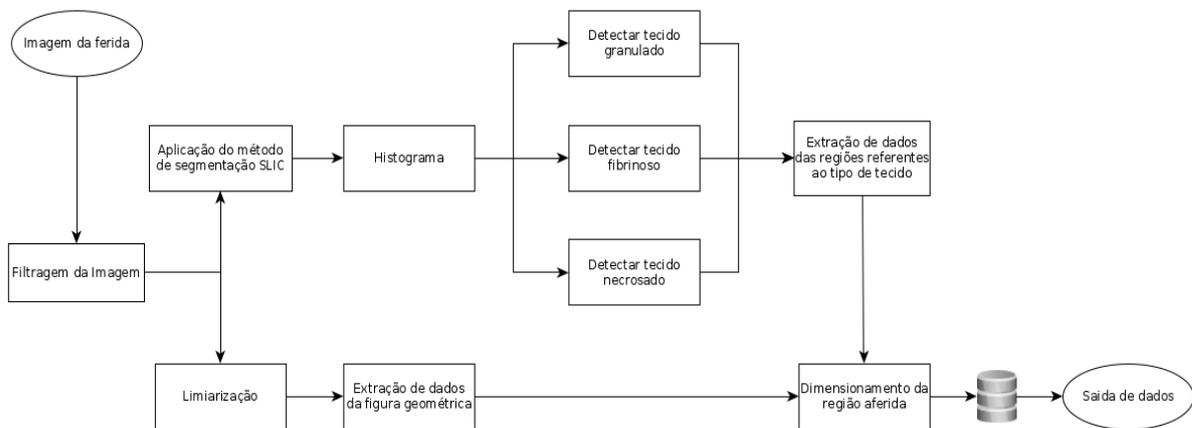


Figura 3.1 – Diagrama da metodologia aplicada.

Portanto, os processo podem ser divididos de acordo com as seguintes etapas:

- 1^a etapa: Aquisição da imagem;
- 2^a etapa: Redimensionamento e filtragem da imagem;
- 3^a etapa: Binarização da imagem e extração de dados referentes ao retângulo;
- 4^a etapa: Aplicação do método de segmentação SLIC;
- 5^a etapa: Criar máscaras para cada tipo de tecido;
- 6^a etapa: Análise de dados referente aos tecidos.

A linguagem de programação python foi utilizada em todas as ferramentas de trabalho, onde todo o processo de manipulação de imagens ocorre por meio da ferramenta OpenCV, utilizando as bibliotecas *skimage*, *mpl_toolkits*, *matplotlib*, *cv2 argparse* e *numpy*, e a interação usuário-máquina foi realizada por meio de um *framework* em Django.

3.2 Aquisição de imagens

As imagens utilizadas neste capítulo são cortesias de Marques [21], que seguiu o seguinte protocolo para aquisição de imagens, com o intuito de realizar o processamento de forma eficiente. Sendo que, todas as imagens foram capturada após a limpeza e imediatamente antes da aplicação da cobertura pelo enfermeiro.

- (1) A imagem deve possuir fundo azul, possibilitando que o fundo seja removido;
- (2) A imagem não deve possuir sombras, portanto fonte de luz deve ser bem focalizada para evitar que tal comportamento ocorra;
- (3) Cores equivalentes fora da região de interesse devem ser evitadas, pois será reconhecida pelo método de segmentação aplicado;
- (4) o flash deve ser desativado para evitar a produção de valores falsos;
- (5) a imagem deve ser formada de forma que o plano da câmera deve ser o mais paralelo possível de ao plano da ferida, fazendo com que o dimensionamento seja mais preciso.

A Figura 3.2, ilustra a aquisição de uma imagem por meio das especificações estabelecidas pelo protocolo utilizado para segmentação de imagens digitais. A imagem encontra-se bem focalizada, sem a ocorrência de sombreamento ou objetos com coloração próxima ao da região de interesse.



Figura 3.2 – Aquisição de imagens conforme requisições estabelecidas pelo protocolo proposto.

3.3 Redimensionamento e Filtragem

Após a aquisição da imagem é necessário realizar um pré-processamento, que é responsável por estabelecer uma métrica ao qual a imagem será submetida no processo de redimensionamento de forma a agilizar o processamento digital da imagem, fazendo com que as imagens adquiridas sejam processadas mais rápidas e ocupem um volume menor no disco ao serem armazenadas.

3.3.1 Redimensionamento da imagem

O redimensionamento é utilizado para diminuir as dimensões de uma imagem por meio de um algoritmo responsável pela exclusão de alguns *pixels* originais da imagem, onde mesmo após a exclusão a avaliação pode ser realizada de forma precisa.

Para o redimensionamento da imagem foi utilizada a função `cv2.resize()`, fazendo com que a imagem possa ser moldada de acordo com o interesse do projeto, acelerando as operações posteriores.

3.3.2 Filtragem da imagem

A filtragem é realizada para retirar o fundo azul da imagem digitalizada (Figura 3.4a), diminuindo o número de informações contidos nas cores apresentadas. Esta etapa faz com que apenas as regiões e objetos de interesse (membro, ferida e molde de dimensionamento) estejam presentes na nova imagem, possibilitando com que o processamento digital ocorra de forma rápida e precisa, pois elimina uma série de segmentos com informações irrelevantes para a análise do problema em questão.

Após levantar um *scatter* no espaço de cores HSV, Figura 3.3, gráfico tridimensional que relaciona os coeficientes espaciais presentes na imagem, é possível verificar qual o intervalo em que os coeficientes estão relacionados com os *pixels* presentes no fundo da imagem, neste caso, basta alterar os valores desse conjunto de *pixels* para 0, substituindo o fundo azul por um fundo preto. Após a remoção dos *pixels* indesejados, são utilizados alguns operadores morfológicos para retirar resíduos sobressalentes. Utilizam-se um filtro de vizinhança para remoção de pontos flutuantes e um filtro gaussiano para eliminação de ruídos e suavização da imagem, conforme ilustrado na Figura 3.4b.

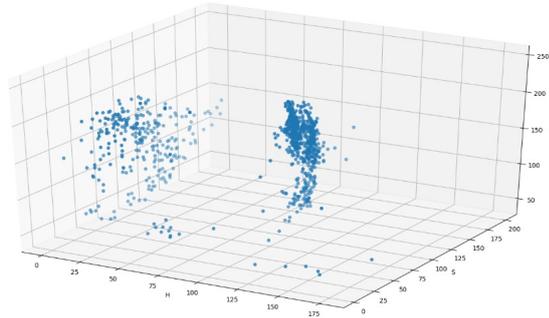


Figura 3.3 – Scatter das médias de cores de cada segmento no espaço *HSV*.



(a) Imagem original



(b) Imagem filtrada

Figura 3.4 – Aplicação de um filtro para remoção do fundo azul presente na imagem.

3.4 Limiarização e extração de dados presentes no retângulo

O retângulo foi moldado com as cores preto e branco de modo que fosse possível realizar a análise dos *pixels* contidos dentro do quadrilátero, onde é possível extraí-lo da imagem após a conversão para níveis de cinza (Figura 3.5a), em seguida ocorre a aplicação de um filtro gaussiano para homogenizar a imagem e por fim ocorre a binarização da imagem, com um limiar no valor de 200, fazendo com regiões fora do interesse sejam retiradas da figura, sobrando apenas o quadrado e pequenos pigmentos, conforme ilustrado na Figura 3.5b.

Mesmo com a aplicação do threshold com um limiar elevado, não é possível isolar o quadrilátero desejado, fazendo com que seja necessário utilizar algumas ferramentas para retirar apenas o objeto de interesse da imagem. Portanto, foram utilizadas as funções *cv2.findContours()* e *cv2.approxPolyDP()*, onde a primeira é responsável por realizar o contorno (perímetro) de um conjunto de *pixels* com mesma intensidade e a segunda de-



Figura 3.5 – Aplicação de binarização para aquisição do quadrilátero.

fine o número de lados que o contorno possui, fazendo com que seja possível representar figuras geométricas. Como a figura em questão é um quadrilátero com valor alto de *pixels*, é possível criar condições lógicas que proporcione a aquisição do objeto em questão, conforme ilustrado na Figura 3.6a. Com o contorno definido é possível criar uma máscara e relacionar a área real do quadrado com a quantidade de *pixels* existentes dentro do objeto, vide Figura 3.6b.

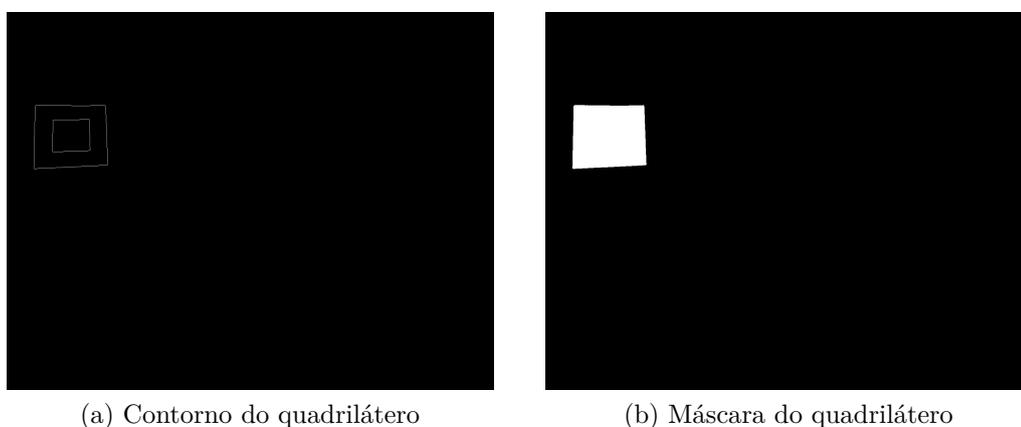


Figura 3.6 – Aquisição da máscara do quadrilátero.

Essa etapa é fundamental para realizar análises posteriores sobre a área dos diferentes tipos de ferida, bem como sua extensão parcial e total. Deste modo é preciso relacionar a área real do quadrilátero com a quantidade de *pixels* existentes dentro da figura geométrica, de modo que seja possível aferir a métrica de qualquer região por meio dessa relação, uma vez que é possível relacionar com um fator que representa a área individual de cada pixel, possibilitando definir também o comprimento de cada pixel.

As dimensões reais do quadrilátero são conhecidas, pois se trata de um quadrado com área de 25cm^2 , uma vez que a máscara é criada é possível identificar o número de

pixels presentes no quadrado, fazendo com que tenhamos

$$Tamanho_{pixel} = \frac{Área_{real}}{k}, \quad (3.1)$$

onde k é a quantidade de *pixels* presentes no quadrado.

Após a aquisição dos dados referentes ao quadrilátero a imagem é redimensionada para que o quadrado seja retirado do processo de segmentação, desta forma o esforço computacional será menor na execução das etapas posteriores, fazendo com que a imagem processada possua as seguintes características.



Figura 3.7 – Imagem após retirada do quadrilátero.

3.5 Aplicação do algoritmo de segmentação SLIC

O método de segmentação SLIC estabelece a quantidade de *superpixels* em uma imagem de acordo com um número k desejado de regiões. Inicialmente, as regiões são formadas por espaçamentos iguais em formato retangular. Conforme a execução das iterações as regiões são modeladas de acordo com a cor e distância espacial existente ao

redor de cada centroide C_k , onde o parâmetro m estabelece uma relação entre a geometria espacial e o espaço de cores $[L * a * b^*]$.

A Figura 3.8 ilustra um caso de segmentação com $k = 4096$ e um valor de $m = 5$, atribuindo maior peso para a distância espacial, fazendo que a segmentação ocorra por *pixels* com cores aproximadas dentro de um limite d , sendo esta a distância máxima permitida entre o pixel central e a vizinhança. Quanto maior o k , mais detalhada será a segmentação, porém maior será o esforço computacional para realizar o processamento da imagem. Podemos ver que mesmo em regiões pequenas com colorações próximas, é possível segmentar os diversos tipos de tecidos, mesmo que as colorações sejam semelhantes no centro da ferida, onde há a separação dos diversos tecidos com tonalidades diferentes de cores, de forma que seja possível realizar a separação dos tecidos por regiões.

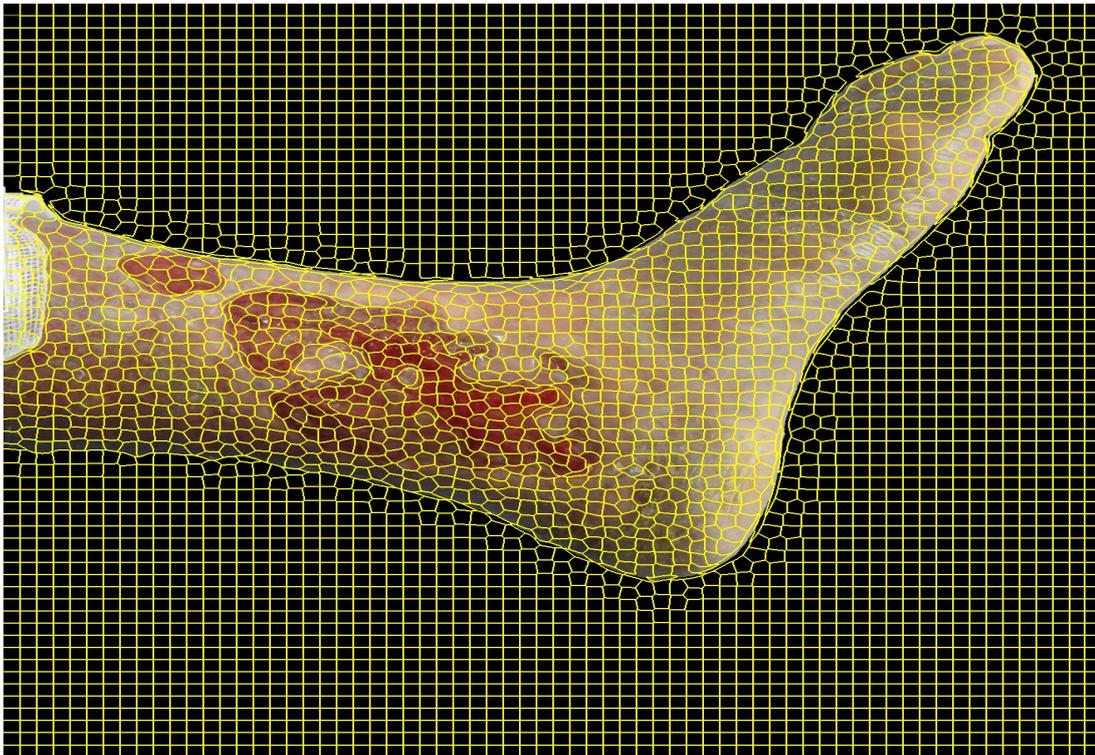


Figura 3.8 – Segmentação utilizando o método SLIC com valores de $k = 4096$ e $m = 5$.

3.5.1 Segmentação dos diferentes tipos de tecidos

Por meio das medias existentes nos agrupamentos de *pixels* dos canais H, S e V, é possível definir uma rotulação para cada *superpixel* como fundo da imagem ou parte da ferida, criando uma máscara para filtrar a parte desnecessária da imagem.

Esta etapa consiste em separar os tecidos em três classificações: granulado, fibrinoso e necrosado. Após a finalização da segmentação pelo método SLIC, cada região ganha uma marcação numérica, conhecida como rótulo, portanto cada segmento é formado por um conjunto de *pixels* que atribuem um valor numérico para cada região. Desta forma, é possível realizar uma média entre todos os pontos presentes em cada segmento, possibilitando a criação de máscaras para cada tipo de tecido de acordo com intervalos dos valores presentes no espaço *HSV*.

Para cada média existente nos n segmentos rotulados, é gerada uma comparação entre a média e alguns intervalos de valores do espaço *HSV* capaz de representar os diferentes tipos de tecidos presentes na região lesionada. Os intervalos foram obtidos de forma empírica, possuindo um máximo e um mínimo para matiz, saturação e valor. Caso a média esteja dentro do intervalo correspondente ao tipo de tecido, o conjunto de *pixels* presente neste segmento será sobreposto em uma máscara correspondente ao tipo de tecido, fazendo com que todos os segmentos de interesse sejam armazenados em máscaras que correspondem aos diferentes tipos de tecidos, conforme ilustrado na Figura 3.9. Caso exista uma região que não foi segmentada corretamente, é possível realizar a inserção ou exclusão do segmento manualmente em uma etapa que será descrita adiante.

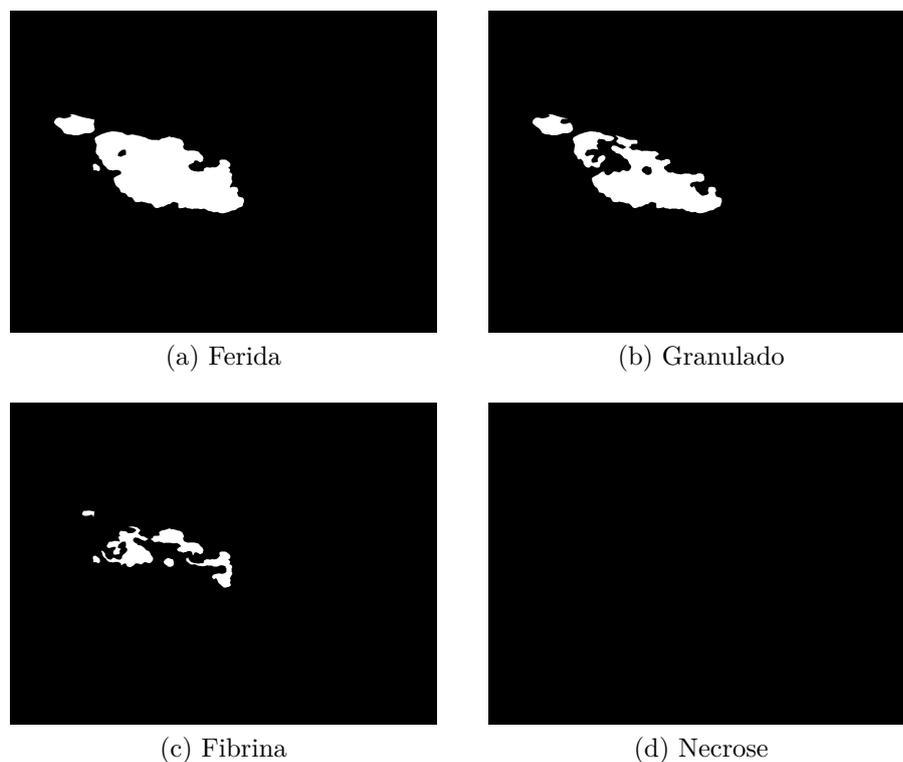


Figura 3.9 – Máscaras correspondentes a cada tipo de tecido.

As máscaras podem ser representadas por dois valores, onde os *pixels* que possuem cor preta possuem valor numérico igual a 0 e os de cor branca possuem valor numérico igual a 1 (valores normalizados). Desta forma, para adquirir a imagem correspondente a cada tipo de tecido, basta fazer uma operação de multiplicação da máscara com a imagem filtrada, onde cada bit (R, G, B) será apresentado nas regiões com múltiplos igual a 1. Para realizar essa operação foi utilizada a função `cv2.bitwise_and()` do openCV, conforme ilustrado na Figura 3.10.

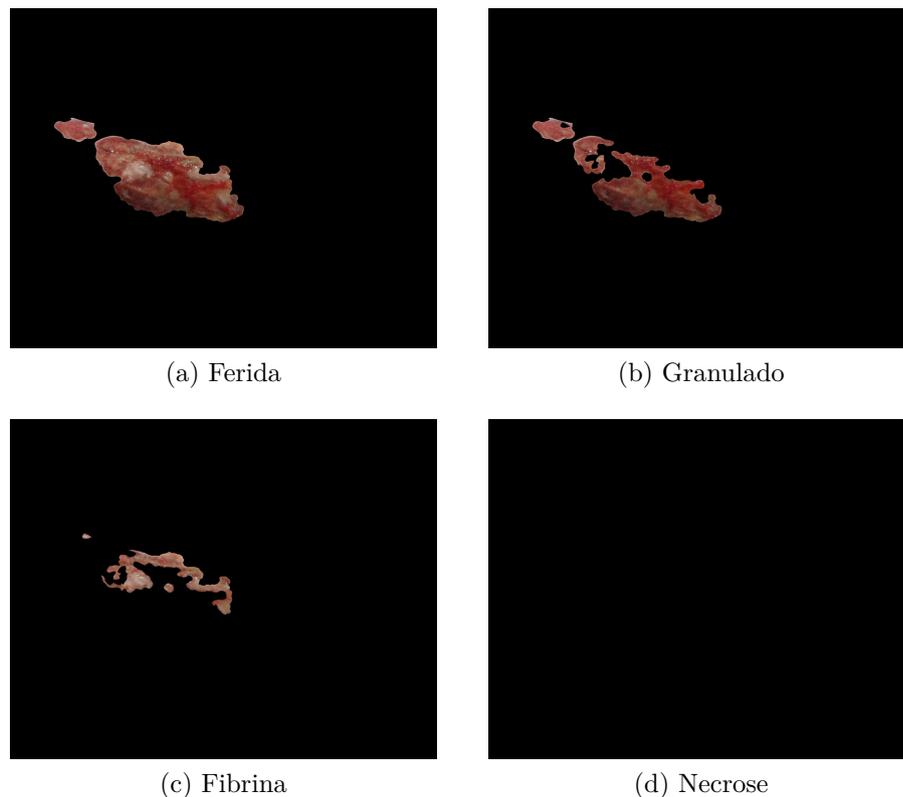


Figura 3.10 – Imagens correspondentes a cada tipo de tecido.

3.6 Dimensionamento da ferida

Para dimensionar uma ferida é necessário inserir um objeto com dimensões conhecidas, de forma que por meio de uma relação entre a quantidade de *pixels* existentes no objeto e a quantidade de *pixels* existente na região de interesse, conforme mencionado na seção 3.4. Após a criação das máscaras, é possível quantizar os *pixels* existentes em cada tipo de tecido, possibilitando calcular a área e outras medidas correspondentes a cada tipo de tecido.

A área pode ser encontrada de acordo com o valor presente na variável $pixel_{value}$, equação 3.1, fazendo com que seja necessário multiplicar a quantidade de $pixels$ por esse valor, fazendo com que o resultado seja a área da região de interesse, i.e, tecido granuloso, conforme ilustrado na equação 3.2

$$area_m = pixel_{value} * pixel_m \quad (3.2)$$

onde,

$area_m$ – aproximação da área real da região de interesse.

$pixel_m$ – quantidade de $pixels$ existentes na região de interesse.

$pixel_{value}$ – representação da área de um pixel.

3.7 Framework

Com o intuito de facilitar a análise dos resultados e gerar uma melhor interação entre o usuário e a máquina, foi criado um *framework* para realizar todo o processamento digital, bem como armazenar dados dos pacientes em um banco de dados e criar diretórios para *backup* com as respectivas imagens manipuladas pelo algoritmo DAF (Dimensionamento e análise de feridas), conforme ilustrado na Figura 3.11.



Figura 3.11 – Página inicial do framework.

A barra de navegação do framework é composta pelas seguintes estruturas: página inicial, *CRUD* (*CREATE, READ, UPDATE AND DELETE*), quadro clínico e tutorial.

3.7.1 Create, Read, Delete and Update – (CRUD)

Toda a base de dados relacionada as informações pessoais do usuário são criadas durante o seu cadastro, fazendo com que os dados sejam armazenados no banco de dados. Após a confirmação do cadastro do usuário um repositório é criado no sistema, onde serão armazenadas todas as imagens inseridas nas estruturas posteriores. Após a criação do usuário é possível realizar a leitura de seus dados, bem como alterar e deletar o usuário do sistema, vide Figura 3.12.

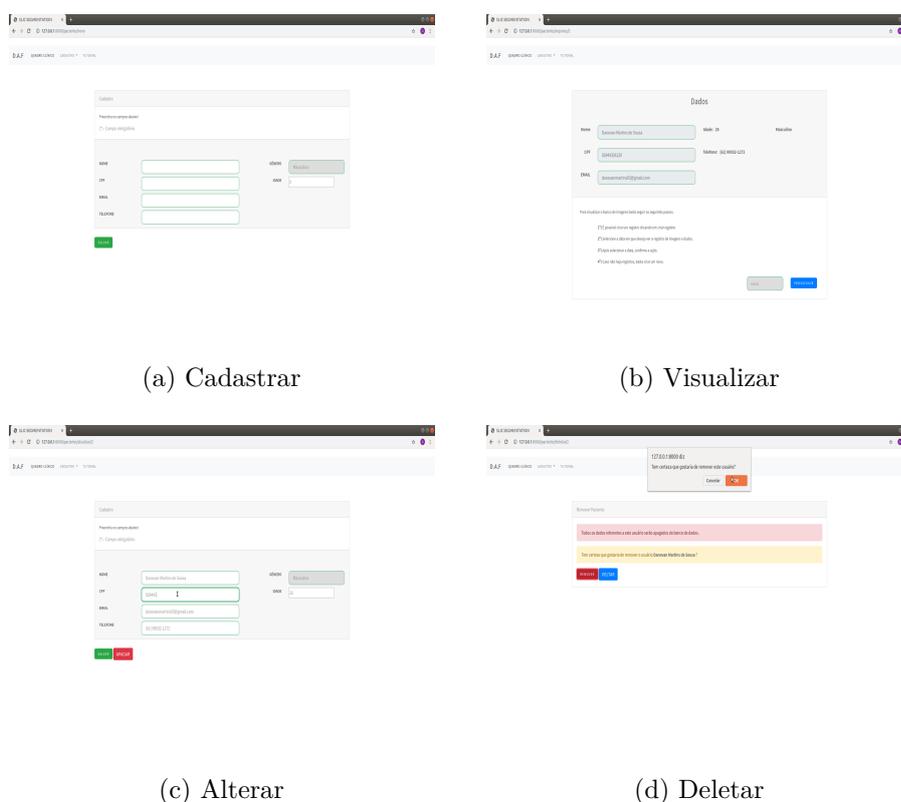


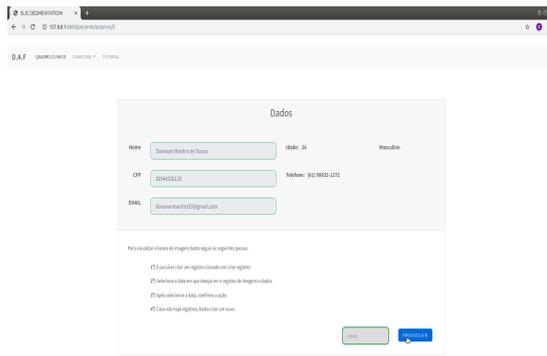
Figura 3.12 – Representação da estrutura CRUD.

3.7.2 Quadro Clínico

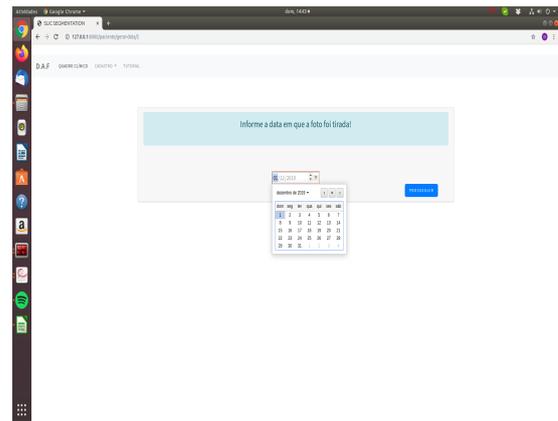
O quadro clínico alerta quais pacientes estão cadastrados no sistema, onde é possível selecionar o usuário ao qual deseja iniciar o processamento digital de dados.

Ao selecionar o paciente ao qual será realizado o procedimento de digitalização, deve-se inserir a data em que a aquisição da imagem ocorreu, pois todo o mapeamento será realizado conforme datas estabelecidas para diferentes aquisições, ilustrado na Figura 3.13.

Após confirmar a escolha da data, um novo diretório será criado com nome equi-



(a) Criar nova aquisição

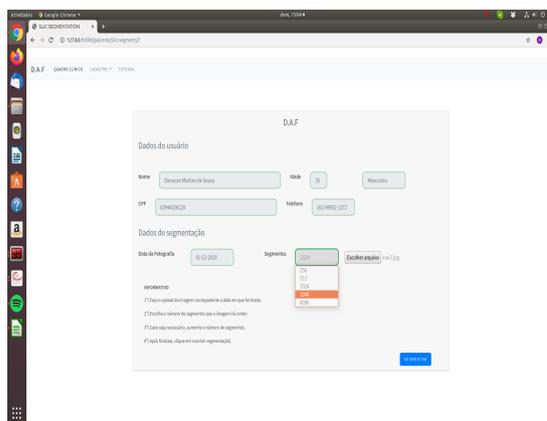


(b) Escolher data de aquisição

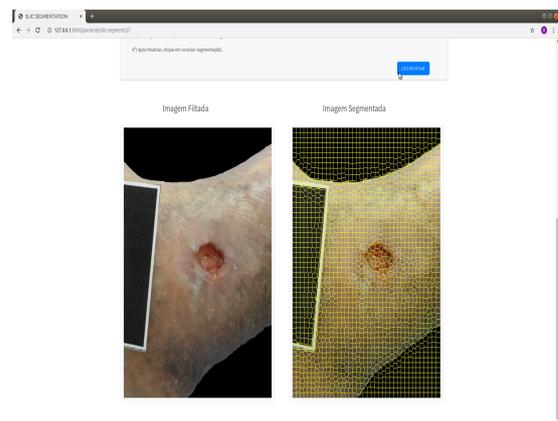
Figura 3.13 – Estabelecendo data da aquisição.

valente a data escolhida, fazendo com que todas as etapas de processamento digital de imagens sejam armazenados conforme usuário e data selecionados, possibilitando o início do pré-processamento e do processamento digital de imagens.

Para iniciar o tratamento digital é necessário conferir os dados do paciente e definir dois parâmetros para iniciar a segmentação; inserção da imagem que será processada; e o número de segmentos que será gerado para rotular as n regiões. Desta forma, pode-se dar início ao processo de segmentação, conforme demonstrado na Figura 3.14.



(a) definir parâmetros de segmentação

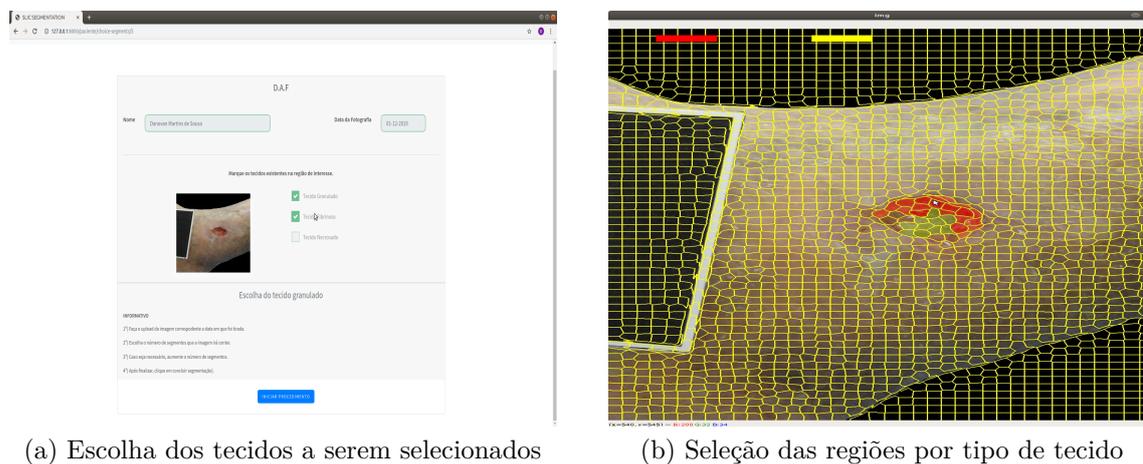


(b) resultado da segmentação

Figura 3.14 – segmentação da imagem inserida.

Ao finalizar a segmentação da imagem, basta selecionar os tipos de tecidos que existem na região segmentada, desta forma será realizada uma seleção automática de um conjunto de regiões que se enquadram dentro do tipo de tecido, sendo possível que estes pontos possam ser retirados na etapa de seleção manual, ao qual o usuário é responsável por analisar qual e o tipo de tecido e selecionar a qual grupo ele pertence, fazendo com

que toda a região possa ser corretamente separada entre os tecidos existentes na região de interesse, Figura 3.15. Os retângulos coloridos na parte superior da imagem são seletores do tipo de tecido, onde é possível selecionar uma região caso ela não esteja marcada, ou desmarcar caso ela possua a mesma coloração do retângulo selecionado.



(a) Escolha dos tecidos a serem selecionados

(b) Seleção das regiões por tipo de tecido

Figura 3.15 – segmentação referente ao tipo de tecido.

Caso exista mais de uma análise para o mesmo usuário, será realizada uma comparação entre a primeira aquisição e a aquisição atual, onde é possível observar dados referentes as dimensões, largura, altura e porcentagem de cada tipo de tecido existente nas análises. Desta forma, é possível avaliar o quadro do paciente ao decorrer do tempo, pois a informação estará armazenada no banco de dados do usuário cadastrado, conforme demonstrado na Figura 3.16.

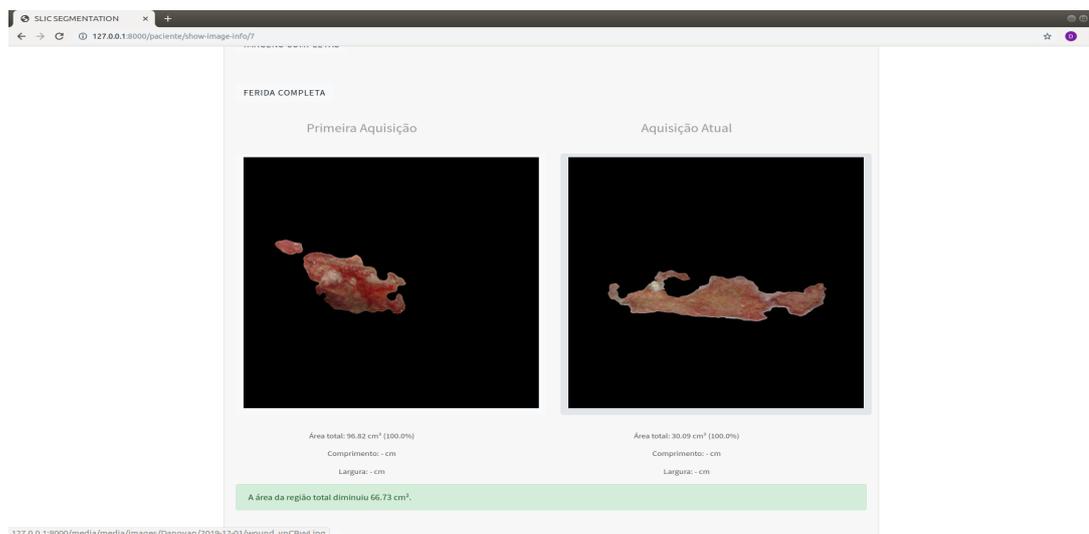


Figura 3.16 – Página inicial do framework.

4 Resultados e Discussões

Este capítulo é responsável por indicar os resultados obtidos durante toda a manipulação digital dos dados adquiridos por meio do protocolo de captura realizado para a aquisição da imagem a ser tratada pelo algoritmo DAF. Algumas análises devem ser realizadas para aferir se o algoritmo realiza o dimensionamento de forma correta, portanto deve-se considerar que o algoritmo não é capaz de aferir a dimensão da ferida, caso: a imagem não possua o quadrado de referência, a região lesionada seja interna ou possua cavidade profunda, o quadrado de referência esteja posicionado em um ângulo muito diferente do plano paralelo ao da ferida, a ferida se estenda de forma a sair da região plana. Portanto, para dimensionar de forma correta, o formato de aquisição deve seguir os critérios apresentados na seção 3.2.

Todas as imagens utilizadas na geração de resultados deste projeto foram adquiridas por Marques [21], restritas pelo fundo de aquisição e formato das feridas, de forma a obter resultados mais precisos e condizentes com a realidade.

Os dados obtidos para cada tipo de tecido são referentes a área total da região lesionada, porcentagem do tecido de acordo com a área total obtida, altura máxima e largura máxima do tecido em análise.

4.1 Análise dos Resultados

O quadro evolutivo de uma ferida crônica é um processo que demora várias semanas para ser concluído, deste modo não foi possível realizar aquisições suficientes de um tratamento completo, portanto, para validar o sistema foram utilizadas 6 imagens, com o intuito de obter os resultados referentes a segmentação das feridas, dentre essas é possível realizar um breve quadro comparativo do um mesmo paciente. Com o processamento digital de imagens é possível aferir a área total da ferida, áreas dos diferentes tipos de tecidos, largura máxima, altura máxima e porcentagem total de cada tecido.

O resultado de segmentação tem uma etapa automática e outra manual, fazendo com que um especialista necessite de validar as regiões que ainda não foram classificadas. Deste modo, os resultados são fundamentados de acordo com a interpretação do especia-

lista ou usuário que esteja classificando o conjunto de tecidos. A tabela 4.1 possui dados obtidos durante o processo de segmentação em 6 imagens utilizando o algoritmo DAF, o número de referência na coluna "imagem" será anexado no final do trabalho.

Tabela 4.1 – Resultado referente às amostras

Imagem	Área Total (cm^2)	Largura (cm)	Altura (cm)	T. Granulado (cm^2 (%))	T. Fibrinoso (cm^2 (%))	T. Necrosado (cm^2 (%))
1	49,10	8,67	6,53	41,92 (85,38)	7,18 (14,62)	0 (0)
2	2,17	2,82	0,96	1,75 (80,65)	0,41 (18,89)	0 (0)
3	3,69	2,53	2,18	2,15 (58,27)	1,54 (41,73)	0 (0)
4	2,80	2,38	1,12	2,02 (72,14)	0,77 (27,50)	0 (0)
5	13,24	8,68	2,56	7,10 (53,63)	6,13 (46,30)	0 (0)
6	8,22	4,44	1,87	6,40 (77,86)	1,81 (22,02)	0 (0)

4.2 Quadro Evolutivo

Feridas crônicas possuem duração prolongada, dificultando o processo de aquisição de imagens para criação do quadro comparativo, portanto, o quadro comparativo será restrito a duas imagens, lembrando que as imagens são cortesias de Marques [21].

4.2.1 Paciente 1

É possível acompanhar o quadro evolutivo do primeiro paciente observando a Figura 4.1, onde a primeira imagem representa a primeira aquisição e a segunda imagem uma nova aquisição realizada 2 semanas após a data da primeira. É possível observar que há uma melhora significativa ao decorrer do tratamento realizado, pois boa parte da região exposta foi cicatrizada.



(a) Imagem 1



(b) Imagem 2

Figura 4.1 – Quadro evolutivo do paciente 1

Após todo o tratamento digital é possível realizar comparações por meio dos dados obtidos, tais como; área, largura e altura (inicial e final); quantidade e porcentagem dos tecidos granuloso, fibrinoso e necrosado; Os dados obtidos estão descritos na Tabela 4.2, onde é possível notar uma redução em todas as dimensões da segunda imagem comparado à primeira.

Tabela 4.2 – Comparativo da progressão de uma ferida – Paciente 1

Imagem	Área Total (cm^2)	Largura (cm)	Altura (cm)	T. Granulado (cm^2 (%))	T. Fibrinoso (cm^2 (%))	T. Necrosado (cm^2 (%))
4	2,80	2,38	1,12	2,02 (72,14)	0,77 (27,50)	0 (0)
5	13,24	8,68	2,56	7,10 (53,63)	6,13 (46,30)	0 (0)

4.2.2 Paciente 2

Podemos realizar as mesmas observações que foram realizadas no paciente 2, apenas mudando o período de aquisição entre as duas imagens e o formato de cicatrização, conforme apresentado na Figura 4.2



Figura 4.2 – Quadro evolutivo do paciente 2

Pela Tabela 4.3 é possível observar que havia uma quantidade muito alta de Fibrina no início do tratamento, dificultando a ação da cicatrização que ocorre por meio do tecido granuloso. Já na segunda imagem temos uma quantidade maior de tecido granuloso que fibrina, indicando que o tratamento está sendo eficiente.

Tabela 4.3 – Comparativo da progressão de uma ferida – Paciente 2

Imagem	Área Total (cm^2)	Largura (cm)	Altura (cm)	T. Granulado (cm^2 (%))	T. Fibrinoso (cm^2 (%))	T. Necrosado (cm^2 (%))
2	2,17	2,82	0,96	1,75 (80,65)	0,41 (18,89)	0 (0)
6	8,22	4,44	1,87	6,40 (77,86)	1,81 (22,02)	0 (0)

4.3 Validação dos dados obtidos

A validação dos dados obtidos foi realizada com o levantamento de um erro associado entre as diferenças existentes com a área encontrada neste estudo e a área levantada por uma ferramenta profissional, ImageJ®, da região lesionada. As duas ferramentas são utilizadas para segmentar a região da ferida, fazendo com que a área possa ser calculada de acordo com os parâmetros encontrados de acordo com a relação existente entre o quadrilátero e os *pixels* existentes em seu interior.

Em algumas imagens a coloração da fibrina se aproxima muito com a coloração da pele, fazendo com que a segmentação automática ocorra de forma errada, desta forma foi necessário implementar a segmentação manual para ambos os estudos, onde por meio de uma ferramenta de seleção livre é possível delimitar a região lesionada.

Levando em consideração que o software ImageJ® é uma ferramenta profissional para a análise de feridas, o erro encontrado pode ser dado em função da seguinte equação

$$Erro = \frac{|A_{Image_J} - A_{DAF}|}{A_{Image_J}} * 100, \quad (4.1)$$

onde, A_{image_J} é a área obtida pelo software ImageJ® e A_{DAF} é a área obtida com os métodos utilizados neste estudo.

De acordo com a Tabela 4.4 é possível analisar se o método de segmentação levantado neste estudo se aproxima ao de um modelo profissional, onde, por meio do erro encontrado, pode-se aferir, com exceção da imagem 4, que o método de segmentação desenvolvido possui pequenas variações com modelos profissionais. Na aquisição dos parâmetros da imagem 4 houve uma divergência com a relação dos *pixels* existentes dentro do quadrilátero, fazendo com que o erro fosse elevado.

Tabela 4.4 – Erro encontrado de acordo com a diferença das áreas

Imagem	A_{DAF} (cm^2)	A_{Image_I} (cm^2)	Erro (%)
2	2,17	2,13	1,88
3	3,69	3,47	6,34
4	2,80	1,86	50,53
5	13,24	14,014	5,52
6	8,22	8,87	7,32

4.4 Comparação com outros trabalhos

Os dados apresentados pela Tabela 4.1 serão comparados com os dados levantados no trabalho de Marques [21], comparando a área total e dos demais tecidos.

Foi utilizado o método SLIC para realizar a segmentação neste trabalho, sendo que a classificação de feridas ocorreu parte automática e parte manual em todas as imagens. Já no trabalho levantado por Marques [21] algumas imagens foram classificadas automáticas e outras precisaram de uma classificação manual. Será realizada uma comparação entre imagens existentes no dois trabalhos, onde a Tabela 4.5 representam os dados obtidos neste trabalhos, que serão comparados aos dados da Tabela 4.6.

Tabela 4.5 – Resultados obtidos neste trabalho

Imagem	Área Total (cm^2)	Largura (cm)	Altura (cm)	T. Granulado (cm^2 (%))	T. Fibrinoso (cm^2 (%))
A	2,17	2,82	0,96	1,75 (80,65)	0,41 (18,89)
B	2,80	2,38	1,12	2,02 (72,14)	0,77 (27,50)
C	13,24	8,68	2,56	7,10 (53,63)	6,13 (46,30)
D	8,22	4,44	1,87	6,40 (77,86)	1,81 (22,02)

Tabela 4.6 – Resultado obtidos por Marques, [21]

Imagem	Área Total (cm^2)	Eixo maior (cm)	Eixo menor (cm)	T. Granulado (cm^2)	T. Fibrinoso (cm^2)
A	1,87	2,91	0,848	1,69	0,19
B	1,89	1,20/0,5	0,91/0,21	1,54	0,39
C	14,32	3,23	1,12	13,4	1,05
D	8,71	5,67/2,14	2,02/1,02	7,71	1,07

Dependendo do modo que a máscara foi criada, os eixos encontrados podem divergir entre as comparações, fazendo com que em alguns resultados os valores encontrados sejam bem diferentes.

5 Conclusões e Trabalhos Futuros

Utilizar ferramentas para aferir medidas de uma região que possui algum tipo de lesão acaba sendo complicado, pois, ferramentas que não são esterilizadas de forma correta, possibilitam a geração de infecções que podem influenciar negativamente no quadro evolutivo do paciente, sendo este um procedimento que exige cautela, acréscimo no período de tratamento e local para armazenamento de dados (planilha, folha etc). Como existe um quadro de pacientes muito grande, é pouco usual realizar este tipo de análise. Desta forma, o uso de uma plataforma com interface para o usuário ou clínico torna o tratamento mais eficiente, podendo aferir dados sobre as dimensões da ferida, bem como levantar um banco de dados para acompanhar a evolução da ferida ao decorrer do tratamento.

A interface criada possibilita que o usuário tenha uma experiência fácil ao gerenciar os dados, seja para armazená-los ou visualizar dados já registrados no sistema. Desta forma, todo o dimensionamento, bem com a segmentação de cada tipo de tecido, fica disponível para que haja a correta análise por uma equipe, sendo possível realizar a rotação do quadro clínico, já que todos podem ter acesso ao banco de imagens e dados de um indivíduo.

Para o correto funcionamento do sistema o algoritmo requer que o protocolo seja seguido conforme estipulado no trabalho, não sendo possível realizar a aquisição de algumas lesões, como feridas profundas ou não-planares.

O tecido possui vários aspectos e colorações próximas a de feridas, portanto para um banco de imagens pequeno é inviável realizar a classificação automática dos segmentos, de forma que não ocorra da maneira correta. Neste caso, é necessário levantar limiares básicos para validar algumas regiões e completar a base de forma manual, selecionando as regiões conforme análise de um especialista. Deste modo, o processo se torna um pouco mais lento que o automático, no entanto possibilita que toda a segmentação ocorra de forma correta e seja possível aferir todo o dimensionamento da ferida, bem como a separação dos tipos de tecidos levantados nesse estudo.

O ambiente natural de aquisição possui fatores que influenciam na aquisição de imagens, por exemplo, uma captura realizada ao meio dia e outra realizada ao entardecer

produzem diversas características diferentes em um ambiente que está sujeito às ações do meio natural, fazendo com que seja necessário a utilização de algum tipo de logo que possua atributos com cores, brilho e contraste conhecidos. Deste modo, é possível realizar um pré-processamento para que todas as imagens do banco possuam um certo padrão na tonalidade, eliminando falsos valores encontrados no espaço *HSV*.

Alguns comparativos com trabalhos já existentes mostram que as dimensões adquiridas são bem próximas de estudos já realizados na segmentação de regiões. É possível analisar que a área de cada região é bem próxima em ambos estudos, onde em algumas figuras, de acordo com o método de segmentação utilizado, há algumas divergências apenas na dimensão encontrada relativa a área de alguns tecidos. Realizando alguns métodos para homogenizar o ambiente de aquisição, fazendo com que a captura seja o mais plana possível, os dados encontrados serão condizentes com a realidade.

O processo de aquisição possui diversas variáveis, sendo assim o sistema possui alguns pontos que devem ser desenvolvidos para melhorar a dinâmica após a aquisição das imagens, fazendo com que seja possível registrar a aquisição correta sem levantar falsos positivos durante o processo de segmentação. Portanto, para trabalhos futuros, planeja-se a criação de classificadores confiáveis, uma vez que haja um aumento significativo no banco de imagens, fazendo com que toda a segmentação ocorra de forma automática. A criação de uma logomarca com alguns padrões é necessário para que permita a realização de um pré-processamento que irá padronizar brilho, contraste e a matiz do conjunto de imagens adquiridas. É importante ressaltar que todo o processo pode ser executado por meio de um aplicativo compatível com a plataforma levantada, possibilitando a criação de um aplicativo integrado para aquisição e manipulação dos dados, por exemplo, *smartphones*.

Referências

- [1] F. P. de; OLIVEIRA, B. G. B. de Oliveira, R. F. Santana, B. d. P. Silva, and J. d. S. C. Candido, “Classificações de intervenções e resultados de enfermagem em pacientes com feridas: mapeamento cruzado,” *Revista Gaúcha de Enfermagem*, vol. 37, no. 2, p. e55033, 2016. Citado na página 15.
- [2] N. A. Cunha, “Sistematização da assistência de enfermagem no tratamento de feridas crônicas,” pp. 1 – 33, 2006. Citado 2 vezes nas páginas 15 e 20.
- [3] M. A. M. Loots, E. N. Lamme, J. R. Mekkes, J. D. Bos, and E. Middelkoop, “Cultured fibroblasts from chronic diabetic wounds on the lower extremity (non-insulin-dependent diabetes mellitus) show disturbed proliferation,” *Archives of Dermatological Research*, vol. 291, pp. 93–99, Mar 1999. Citado na página 15.
- [4] B. L. L. Cavalcante and U. T. S. Lima, “Relato de experiência de uma estudante de Enfermagem em um consultório especializado em tratamento de feridas,” *Journal of Nursing and Health*, vol. 2, no. 1, pp. 94–103, 2010. Citado na página 16.
- [5] É. A. G. Dorileo, M. A. C. Frade, R. M. Rangayyan, and P. M. Azevedo-marques, “SEGMENTATION AND ANALYSIS OF THE TISSUE COMPOSITION OF DERMATOLOGICAL ULCERS School of Medicine of Ribeirão Preto , University of São Paulo , Ribeirão Preto , Department of Electrical and Computer Engineering , Schulich School of Engineering , University ,” pp. 2–5. Citado na página 16.
- [6] S. H. Mandelbaum, É. P. Di Santis, and M. H. S. Mandelbaum, “Cicatrização: conceitos atuais e recursos auxiliares-Parte I Cicatrization: current concepts and auxiliary resources-Part I,” *Anais Brasileiro de Dermatologia*, vol. 78, no. 4, pp. 393–410, 2003. Citado na página 18.
- [7] L. Blanes, “Tratamento de feridas, Cirurgia vascular: guia ilustrado. são paulo,” *ptits-Silva JCC, editor*, no. 1, 2004. Citado na página 19.
- [8] “CURSO AVANÇADO NO TRATAMENTO DE FERIDAS.” <http://www.ebah.com.br/content/ABAAABhdgAG/>

- [curso-avancado-no-tratamento-feridas-busc-ativa?part=4](#). Acessado em: 19-06-2018. Citado na página 20.
- [9] R. C. Gonzalez and R. E. Woods, *Digital Image Processing (3rd Edition)*. 2007. Citado 9 vezes nas páginas 20, 21, 22, 25, 27, 28, 29, 32 e 33.
- [10] O. M. Filho and H. V. Neto, *Processamento Digital de Imagens*, vol. 21/03. 1999. Citado 2 vezes nas páginas 21 e 26.
- [11] L. O. Observer, “Colorimetric Fundamentals,” pp. 1–2, 1976. Citado na página 23.
- [12] “The Truth About Color.” https://www.bonlalum.com/education/the_truth_about_color.shtml. Acessado em: 04-07-2018. Citado na página 23.
- [13] T. B. Moeslund, *Introduction to Video and Image Processing*. 2012. Citado na página 24.
- [14] “HSV color space-Hue, saturation, value .” https://www.researchgate.net/figure/HSV-color-space-Hue-saturation-value_fig1_284698928. Acessado em: 03-12-2019. Citado na página 24.
- [15] “Filtragem espacial.” <https://pt.stackoverflow.com/questions/252076/problemas-com-aplicacao-de-filtro-gaussiano>. Acessado em: 29-06-2018. Citado na página 26.
- [16] “DARK MESSENGER.” <http://sf.co.ua/id35543>. Acessado em: 03-10-2018. Citado 2 vezes nas páginas 27 e 33.
- [17] “Picture of the Day: Macro Rose.” <https://twistedgifter.com/2014/09/macro-rose-by-marta-varela/>. Acessado em: 03-10-2018. Citado 2 vezes nas páginas 31 e 32.
- [18] D. S. D. Freitas, “Representação Baseada em Superpixels para a Segmentação de Lesões Melanocíticas em Imagens Macroscópicas Representação Baseada em Superpixels para a Segmentação de Lesões Melanocíticas em Imagens,” 2016. Citado 2 vezes nas páginas 34 e 35.
- [19] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk, “Slic superpixels compared to state-of-the-art superpixel methods,” vol. 34, 05 2012. Citado na página 34.

-
- [20] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk, “SLIC Superpixels,” *EPFL Technical Report 149300*, 2010. Citado 2 vezes nas páginas 34 e 35.
- [21] C.-o. S. D. S. R. F. Rosa, “Universidade de Brasília - UnB Faculdade UnB Gama - FGA Curso de Engenharia Eletrônica SEGMENTAÇÃO E CLASSIFICAÇÃO AUTOMÁTICA Autora : Marina Pinheiro Marques Orientador : Renan Utida Ferreira,” pp. 1–72, 2014. Citado 5 vezes nas páginas 37, 39, 51, 52 e 55.

6 Anexos

Imagem 1

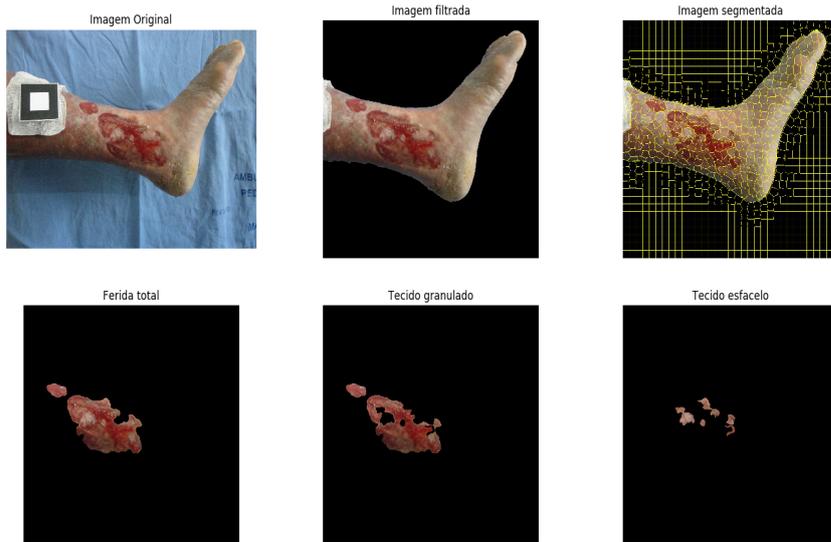


Imagem 2

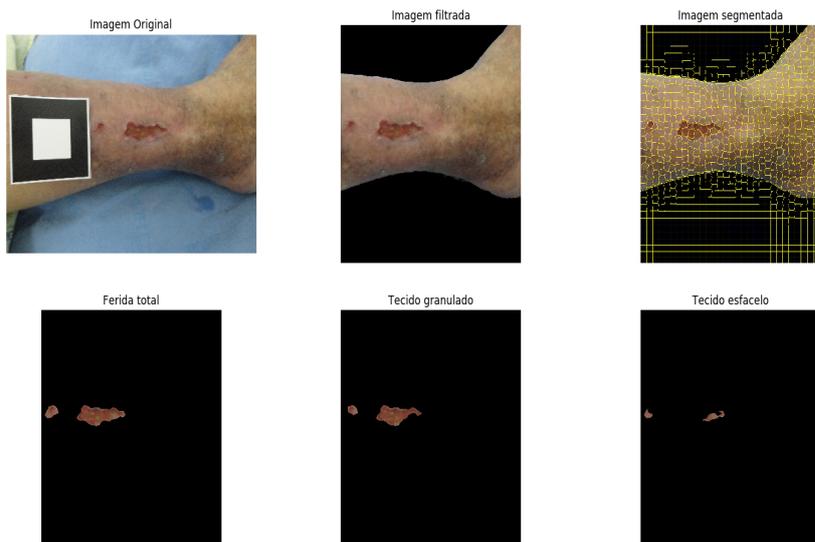


Imagem 3

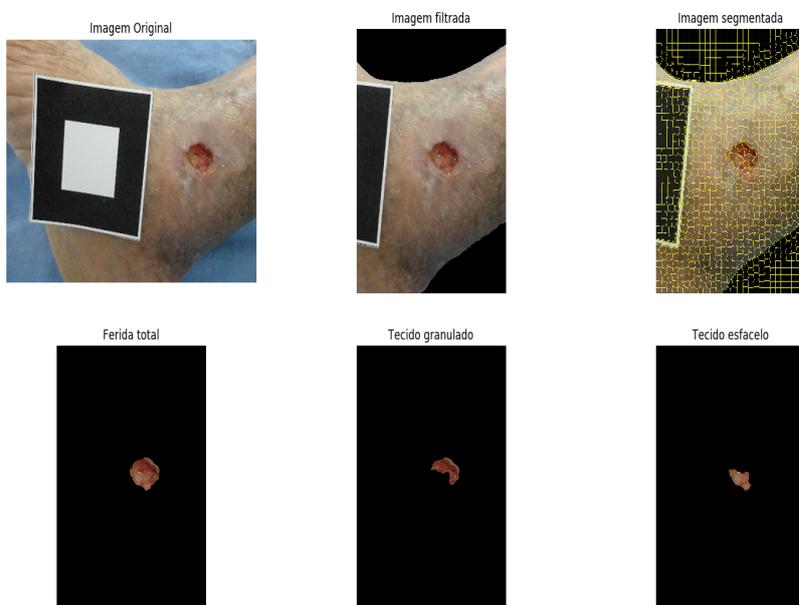


Imagem 4

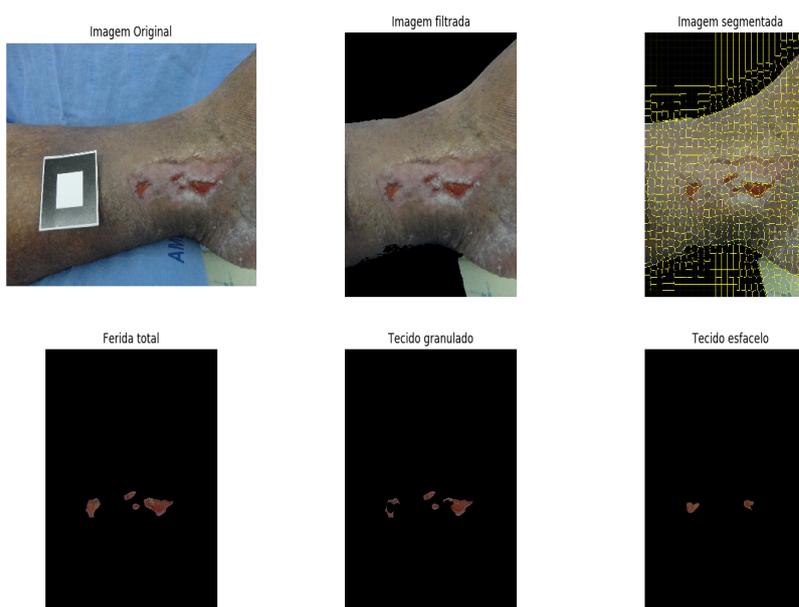


Imagem 5

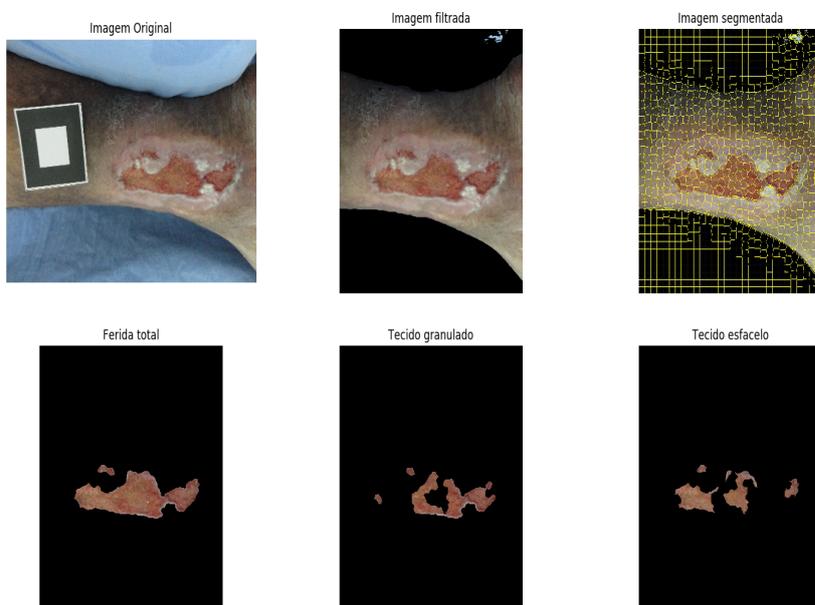


Imagem 6

