

**MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA BAIANO -
CAMPUS CATU
CURSO TECNÓLOGO EM ANÁLISE E DESENVOLVIMENTO DE SISTEMAS**

TRABALHO DE CONCLUSÃO DE CURSO

Isis Beatriz Souza Pereira

Orientador(a): André Luiz Andrade Rezende

BIO-CV

**Um modelo de Análise Automatizada de Ferimentos Cutâneos por Imagem
Fotográfica**

CATU-BAHIA

2026

Pereira, Isis Beatriz Souza

P436b BIO-CV: um modelo de análise automatizada de ferimentos cutâneos por imagem fotográfica/ Isis Beatriz Souza Pereira.- Catu, BA, 2026.
96p.; il.: color.

Inclui bibliografia.

Trabalho de Conclusão de Curso (Graduação em Tecnologia em Análise e Desenvolvimento de Sistemas) – Instituto Federal de Educação, Ciência e Tecnologia Baiano – Campus Catu.

Orientador: Prof. Dr. André Luiz Andrade Rezende.

1. Feridas cutâneas. 2. Visão computacional. 3. Mensuração automatizada. 4. Análise de imagens. I. Instituto Federal de Educação, Ciência e Tecnologia Baiano. II. Rezende, André Luiz Andrade (Orient.). III. Título.

CDU: 616-001.4:004

Resumo

Feridas cutâneas representam um problema de saúde pública que afeta milhões de pessoas, causando desconforto e gerando custos elevados ao sistema de saúde. O acompanhamento adequado dessas lesões é fundamental para monitorar o processo de cicatrização. Apesar dos avanços tecnológicos, a mensuração de feridas ainda é realizada predominantemente de forma manual, utilizando régua descartáveis ou folhas de acetato, métodos que apresentam baixa precisão, resultados subjetivos e podem representar riscos de infecção ao paciente. Este trabalho investigou o desenvolvimento de um sistema capaz de analisar ferimentos cutâneos de forma automatizada por meio de imagens fotográficas. A hipótese central sustenta que a Visão Computacional viabiliza o desenvolvimento de um sistema capaz de mensurar a área do ferimento e reconhecer as cores presentes na lesão. O objetivo geral foi desenvolver um sistema capaz de medir a área do ferimento e identificar as cores presentes de forma automatizada mediante registros fotográficos. Os objetivos específicos incluíram: implementar um algoritmo que identifica o ferimento; desenvolver uma função para calcular automaticamente a área; criar um módulo para identificar as cores; e integrar uma interface gráfica para visualização dos resultados. O sistema Bio-CV foi desenvolvido utilizando Python, OpenCV e técnicas clássicas de visão computacional, implementando três algoritmos principais: segmentação por Active Contour para detecção de bordas, calibração através de adesivo de referência (1 cm²) para cálculo de área real, e clustering K-Means para análise cromática segundo o sistema RYB. Os testes com 50 imagens de datasets públicos demonstraram que o sistema consegue segmentar ferimentos com diferentes morfologias, fornecendo métricas dimensionais (área, perímetro, circularidade, solidez), quantificação cromática objetiva, e interface integrada para visualização dos resultados. O trabalho confirma a viabilidade técnica da análise automatizada de ferimentos cutâneos, oferecendo potencial para maior precisão, diminuição no risco de contaminação e melhoria na qualidade de vida dos pacientes.

Palavras-chave: Feridas cutâneas, Visão computacional, Mensuração automatizada, Análise de imagens.

Abstract

Cutaneous wounds represent a public health problem affecting millions of people, causing discomfort and generating high healthcare costs. Adequate monitoring of these injuries is fundamental for healing process assessment. Despite technological advances, wound measurement is still performed predominantly manually using disposable rulers or acetate sheets, methods presenting low precision, subjective results, and infection risks. This work investigated developing a system capable of automatically analyzing cutaneous wounds through photographic images. The central hypothesis maintains that Computer Vision enables developing a system capable of measuring wound area and recognizing colors present in the lesion. The general objective was to develop a system capable of measuring wound area and identifying colors automatically through photographic records. Specific objectives included: implementing an algorithm that identifies wounds; developing a function to automatically calculate area; creating a module to identify colors; and integrating a graphical interface for results visualization. The Bio-CV system was developed using Python, OpenCV and classical computer vision techniques, implementing three main algorithms: Active Contour segmentation for edge detection, calibration through reference sticker (1 cm²) for real area calculation, and K-Means clustering for chromatic analysis according to the RYB system. Tests with 50 images from public datasets demonstrated that the system can segment wounds with different morphologies, providing dimensional metrics (area, perimeter, circularity, solidity), objective chromatic quantification, and integrated interface for results visualization. The work confirms the technical feasibility of automated cutaneous wound analysis, offering potential for greater precision, decreased contamination risk, and improved patient quality of life.

Keywords: Cutaneous wounds, Computer vision, Automated measurement, Image analysis.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 01: Ferimento cutâneo | 7 |
| Figura 02: Mensuração com o uso de régua descartável | 9 |
| Figura 03: Representação do Sistema RYB | 11 |
| Figura 04: Tumor cerebral detectado através de visão computacional | 23 |
| Figura 05: Imagem original de lesão por pioderma gangrenoso utilizada para demonstração do método de segmentação | 24 |
| Figura 06: Região de interesse (ROI) delimitada manualmente sobre a lesão..... | 25 |
| Figura 07: Imagem convertida para escala de cinza | 26 |
| Figura 08: Imagem após aplicação do filtro Gaussiano (kernel 5x5) | 26 |
| Figura 09: Contorno inicial (elipse) para o algoritmo Active Contour | 27 |
| Figura 10: Contorno final após convergência do Active Contour | 28 |
| Figura 11: Máscara binária da região segmentada | 29 |
| Figura 12: Ferimento isolado após aplicação da máscara | 30 |
| Figura 13: Visualização final com overlay do contorno detectado | 31 |
| Figura 14: Remoção do fundo da imagem | 33 |
| Figura 15: Canais de cores extraídos | 34 |
| Figura 16: Visualização da distribuição cromática | 37 |
| Figura 17: Visualização da quantificação de cores | 38 |
| Figura 18: Ilustração do Ciclo PDCA | 39 |
| Figura 19: Ilustração do PDSII | 40 |
| Figura 20: Tela de cadastro de ferimento | 57 |
| Figura 21: Tela de envio de imagens | 57 |
| Figura 22: Tela análise de resultados | 58 |
| Figura 23: Fluxograma do funcionamento do BIO-CV | 60 |
| Figura 24: Resultados da detecção por Active Contour em diferentes tipos de ferimentos | 62 |

| | |
|--|----|
| Figura 25: Detecção do adesivo de referência | 68 |
| Figura 26: Visualização das métricas calculadas | 69 |
| Figura 27: Detecção do adesivo de referência | 73 |
| Figura 28: Visualização das métricas calculadas | 75 |
| Figura 29: Interface de processamento do Bio-CV | 81 |
| Figura 30: Interface de resultados completos do sistema Bio-CV | 82 |

LISTA DE SIGLAS

ANOVA - Analysis of Variance (Análise de Variância)

AUC - Area Under the Curve (Área Sob a Curva)

AZH - Advancing the Zenith of Healthcare

CNN - Convolutional Neural Network (Rede Neural Convolucional)

CPU - Central Processing Unit (Unidade Central de Processamento)

CSV - Comma-Separated Values (Valores Separados por Vírgula)

DFU - Diabetic Foot Ulcer (Úlcera do Pé Diabético)

FCM - Fuzzy C-Means

HOG - Histogram of Oriented Gradients (Histograma de Gradientes Orientados)

HSL - Hue-Saturation-Lightness (Matiz-Saturação-Luminosidade)

HSV - Hue-Saturation-Value (Matiz-Saturação-Valor)

KAC - Krippendorff's Alpha Coefficient (Coeficiente Alpha de Krippendorff)

Lab - Lightness-a-b (Luminosidade-a-b)

LBP - Local Binary Pattern (Padrão Binário Local)

LED - Light-Emitting Diode (Diodo Emissor de Luz)

MCC - Matthews Correlation Coefficient (Coeficiente de Correlação de Matthews)

MCP - Model Context Protocol (Protocolo de Contexto de Modelo)

PPV - Positive Predictive Value (Valor Preditivo Positivo)

ROI - Region of Interest (Região de Interesse)

RYB - Red-Yellow-Black (Vermelho-Amarelo-Preto)

SLIC - Simple Linear Iterative Clustering (Agrupamento Iterativo Linear Simples)

SPCD - Superpixel Colour Descriptor (Descritor de Cor de Superpixel)

SVM - Support Vector Machine (Máquina de Vetores de Suporte)

YCbCr - Luminance-Chrominance Blue-Chrominance Red (Luminância-Crominância Azul-Crominância Vermelha)

SUMÁRIO

| | |
|---|-----------|
| 1. Introdução..... | 09 |
| 1.1. Problema..... | 09 |
| 1.2. Hipótese..... | 09 |
| 1.3. Justificativa..... | 10 |
| 1.4. Objetivo Geral..... | 10 |
| 1.5. Objetivos Específicos..... | 11 |
| 2. Fundamentação Teórica..... | 11 |
| 2.1. Ferimentos cutâneos..... | 12 |
| 2.2 Tecnologia e saúde..... | 16 |
| 2.2.1 Trabalhos Correlatos..... | 16 |
| 2.2.2 Visão Computacional..... | 25 |
| 2.2.3. Visão Computacional na Saúde..... | 27 |
| 2.2.4. Open Source Computer Vision..... | 28 |
| 2.2.5. Técnicas de Visão computacional para análise de imagens..... | 29 |
| 2.2.6. Técnicas de Visão Computacional para Análise de Cores..... | 38 |
| 3. Metodologia..... | 45 |
| 3.1 PDCA..... | 46 |
| 3.2 PDSII..... | 47 |
| 3.2 Primeiro Ciclo PDCA - Desenvolvimento Dos Algoritmos..... | 48 |
| 3.2.1 PLAN (Planejar)..... | 49 |
| 3.2.2 DO (Fazer)..... | 50 |
| 3.2.3 CHECK (Verificar)..... | 51 |
| 3.2.4 ACT (Agir)..... | 51 |
| 3.3 Segundo Ciclo PDCA - Interface E Integração..... | 52 |
| 3.3.1 PLAN (Planejar)..... | 53 |
| 3.3.2 DO (Fazer)..... | 53 |
| 3.3.3 CHECK (Verificar)..... | 54 |
| 3.3.4 ACT (Agir)..... | 55 |
| 4. Solução..... | 55 |
| 4.1 Requisitos do Sistema..... | 56 |
| 4.1.1 Requisitos funcionais..... | 56 |
| 4.1.2 Requisitos não funcionais..... | 56 |
| 4.2 Arquitetura do Sistema..... | 57 |
| 4.2.1 Organização dos Módulos..... | 57 |
| 4.2.2 Fluxo de Dados..... | 58 |
| 4.3 Módulo de Processamento de Imagem..... | 58 |
| 4.3.1 Algoritmo de Detecção de Bordas..... | 59 |
| 4.3.2 Cálculo de Área..... | 60 |

| | |
|--|-----------|
| 4.3.3 Análise Cromática..... | 61 |
| 4.4 Interface Gráfica..... | 62 |
| 4.5 Integração e Funcionamento..... | 64 |
| 5. Resultados e discussões..... | 67 |
| 5.1 Considerações Iniciais sobre a Validação..... | 67 |
| 5.2 Validação Funcional dos Algoritmos de Processamento de imagem..... | 68 |
| 5.2.1 Algoritmo de Detecção de Bordas com Active Contour..... | 68 |
| 5.2.2 Algoritmo de Cálculo de área..... | 73 |
| 5.2.3 Algoritmo de Análise Cromática..... | 80 |
| 5.3 Apresentação dos Resultados Integrados do Sistema..... | 87 |
| 6. Considerações Finais..... | 91 |
| 7. Referências..... | 93 |

1. Introdução

Ferimentos, independente da sua causa primária ou classificação médica, representam um grande problema de saúde pública, visto que milhões de pessoas são portadoras de algum tipo de lesão. Além de causarem desconforto e diminuir a qualidade de vida das pessoas acometidas, também representam um grande custo ao sistema de saúde.

O acompanhamento dessas lesões é um fator determinante para definir o tratamento correto e monitorar o processo de cicatrização, dessa forma garantindo o sucesso do tratamento, que resulta na cicatrização da ferida. Dessa forma o rastreamento do ferimento é indispensável, conhecer as medidas e características do ferimento é importante para que se obtenha informações relevantes para o acompanhamento.

Mesmo com avanços tecnológicos, os profissionais ainda fazem a mensuração do ferimento de forma manual, utilizando régua descartáveis ou folhas de acetato. Essas técnicas são pouco precisas, tornam os resultados subjetivos, além de estar sujeito a erro humano, e representar riscos de infecção e desconforto ao paciente.

1.1. Problema

Este trabalho se propõe a investigar a possibilidade do desenvolvimento de um sistema que busca analisar ferimentos cutâneos por meio de imagens fotográficas. Partindo da imagem, as principais informações a serem quantificadas são a área do ferimento e as cores presentes no mesmo, provendo uma análise automática da lesão.

Sendo assim, a questão de pesquisa levantada para esse Trabalho de Conclusão de Curso foi a seguinte: **É possível desenvolver um sistema que analisa ferimentos cutâneos de forma automatizada por meio de imagens fotográficas?**

A hipótese que surge diante desse questionamento, está descrita na subseção 1.2, a seguir.

1.2. Hipótese

A hipótese levantada aponta para um cenário em que a Visão Computacional, viabiliza desenvolver um sistema que seja capaz de mensurar a área do ferimento e

reconhecer as cores presentes na lesão, possibilitando o desenvolvimento de um sistema que atenda a questão levantada e exposta na subseção 1.1 (Problema).

1.3. Justificativa

A medição precisa da área de feridas é um fator de extrema importância para obter um tratamento adequado e um acompanhamento preciso do processo cicatricial (Alonso *et al.*, 2023). Segundo Dastjerdi *et al.* (2019) o método mais comumente utilizado nas práticas clínicas para a mensuração de ferida é obter as dimensões lineares da ferida com uma régua.

Entretanto, como destacado por Barbosa (2020), os métodos manuais apresentam desvantagens significativas, tais como o desconforto causado ao paciente durante a mensuração, possibilidade de contaminação do médico e/ou paciente e potencial subjetividade no resultado da medição.

A utilização da telemedicina, uso de tecnologias da informação para atendimento, na área da saúde, de qualidade efetiva a distância (Lisboa *et al.*, 2023), somada a ferramentas como Visão Computacional e Inteligência Artificial, tem representado avanço na área da saúde, considerando especialmente a possibilidade de análise de grandes volumes de dados, como resultados laboratoriais, imagens de exame e mensuração de ferimentos.

Dessa forma, usufruir de sistemas que visam não substituir o profissional de saúde, mas sim automatizar sob supervisão, a mensuração de ferimentos, pode trazer inúmeros benefícios, como: maior precisão de resultados, diminuição no risco de contaminação e benefícios significativos para a melhora na qualidade de vida dos pacientes acometidos por esse tipo de ferimento.

É neste cenário que o presente trabalho se sustenta, buscando desenvolver um sistema que seja capaz de realizar a mensuração de ferimentos de forma automatizada, em busca de solucionar os problemas e buscar os ganhos supracitados.

1.4. Objetivo Geral

Dentro deste recorte o presente trabalho objetiva desenvolver um sistema capaz de medir a área do ferimento e identificar as cores presentes no mesmo de forma automatizada mediante registros fotográficos.

1.5. Objetivos Específicos

Para que o objetivo geral seja obtido, é necessário percorrer os seguintes objetivos específicos:

1. Implementar um algoritmo que identifica o ferimento na imagem enviada;
2. Desenvolver uma função para calcular automaticamente a área do ferimento a partir da imagem identificada;
3. Criar um módulo para identificar as diferentes cores presentes no ferimento;
4. Integrar uma interface gráfica que permita a visualização dos resultados da análise;

2. Fundamentação Teórica

Esta seção apresenta o embasamento teórico necessário para compreender e sustentar a investigação sobre a utilização da visão computacional para a análise automática de ferimentos cutâneos. A fundamentação teórica está organizada em dois eixos principais que se complementam para subsidiar a resposta à questão de pesquisa proposta.

O primeiro eixo aborda ferimentos cutâneos, apresentando conceitos, a importância do processo cicatricial e seu acompanhamento, métodos tradicionais de avaliação e a relação estabelecida entre as cores identificadas no ferimento. Essa base é fundamental para compreender os problemas enfrentados e a necessidade do presente trabalho.

O segundo eixo foca em desenvolver sobre a utilização de tecnologias na área da saúde, especialmente a tecnologia em questão neste trabalho, a visão computacional, explorando definições, aplicações já aplicadas na medicina e as principais técnicas relevantes para a solução proposta. As informações abordadas neste tópico tecnológico oferecem o suporte necessário para o desenvolvimento de sistemas automatizados de análise.

A relação entre esses dois campos de conhecimento fornece a base conceitual e técnica para a obtenção de um sistema que una precisão técnica e relevância das informações obtidas, colaborando com o objetivo final estabelecido.

2.1. Ferimentos cutâneos

A pele é o maior órgão do corpo humano, ela desempenha um papel de suma importância no corpo, participando de diferentes processos como proteção, síntese da vitamina D, excreção e regulação da temperatura, assim sendo, danos a ela podem significar um grande risco (Tottoli *et al.* 2020).

De acordo com Nagle, Stevens e Wilbraham (2023), uma ferida é definida como a lesão ou a interrupção da integridade celular, anatômica e/ou funcional dos tecidos da pele. A depender das causas e das consequências relacionadas ao ferimento, ele pode ser classificado como agudo ou crônico, as feridas agudas costumam passar por um processo de reparo organizado e apropriado, recuperando integridade e funcionalidade. Por outro lado, feridas crônicas não passam por um processo cicatricial linear, prejudicando a recuperação da integridade e funcionalidade do tecido (Tottoli *et al.* 2020).

Figura 01: Ferimento cutâneo



Fonte: Coloplast Brasil (Entendendo as skin tears ou lesões por fricção, 2021)

A incidência de feridas crônicas foi estimada entre 1,51 e 2,21 por 1.000 habitantes no mundo, segundo Zhu *et al.* (2022), e no Brasil, segundo Monteiro de Menezes *et al.* (2022), foi constatado que aproximadamente 3% da população é afetada por alguma forma de lesão cutânea e esses números tendem a aumentar com o envelhecimento das populações.

Em complemento aos autores supracitados, temos Vigneron e Domingos (2021) que destacam como é importante observar de forma contínua os fatores locais, externos, e sistêmicos relacionados ao surgimento da ferida, ou que interfiram no processo cicatricial.

Segundo Silva *et al.* (2024) a cicatrização de uma ferida consiste em uma cascata de eventos que culminam com a reconstituição tecidual. Normalmente o processo cicatricial passa por três fases: inflamatória, proliferação (ou granulação) e remodelamento (ou maturação).

Em complemento Guo e Dipietro (2010) destacam que o processo de cicatrização é complexo e influenciado por múltiplos fatores, condições como diabetes, idade avançada, estado nutricional, perfusão tecidual e estado imunológico podem impactar significativamente a capacidade de reparo tecidual. Nesse sentido, uma abordagem individualizada torna-se crucial.

A recomendação é que se faça uma avaliação semanal do ferimento, utilizando um instrumento padronizado, que possa garantir a confiabilidade e padronização dos dados, para que se possa evoluir de forma devida com processo de cicatrização (Santos *et al.*, 2017).

O acompanhamento desse processo é de suma importância para a adequação ou o desenvolvimento de um plano de tratamento, de acordo com Bervig *et al.* (2021), e isso apenas é possível a partir da documentação do mesmo. Esses dados também são determinantes para avaliar a eficácia do tratamento.

Deve-se destacar que a qualidade do tratamento e da assistência oferecida durante esse período impacta diretamente na qualidade de vida dos pacientes (Pontes, 2023). Além disso, (Coutinho *et al.*, 2020) ressalta que uma avaliação incorreta do ferimento pode acarretar complicações e atraso no processo de cicatrização


Nesse contexto, a mensuração dos ferimentos cutâneos é uma etapa indispensável durante o tratamento. Os dados sobre o processo de cicatrização são fundamentais para basear as decisões do tratamento Bervig *et al.* (2021). Sendo assim, quanto mais precisa e exata é a medição, mais confiável e eficaz é o tratamento.

Dentre as duas principais técnicas manuais para a mensuração de ferimentos, a primeira e mais simples (e padrão) é baseada em uma régua descartável, que

calcula a área multiplicando a o maior comprimento pela maior largura, como destacado por (Alves *et al*, 2022).

A segunda técnica, também exposta por Alves *et al* (2022), é o rastreamento transparente, nessa técnica é utilizada uma folha de acetato quadriculada ou um plástico transparente colocado sob o ferimento sendo mesmo é contornado, e com base no contorno obtido a área é calculada.

Figura 02: Mensuração com o uso de régua descartável



Fonte: Feridas Crônicas (PREVENÇÃO E MANEJO DA LESÃO POR PRESSÃO: Manejo da lesão por pressão, 2020)

Contudo, como destacado por Barbosa (2020), os métodos manuais são considerados invasivos e apresentam desvantagens significativas, tais como o desconforto causado ao paciente durante a mensuração, e potencial subjetividade no resultado da medição.

Em complemento, Weigelt *et al.* (2022) destaca que as metodologias atuais de avaliação de feridas são predominantemente subjetivas e baseadas na experiência clínica, evidenciando a necessidade de ferramentas diagnósticas objetivas que possam transformar o tratamento de feridas numa abordagem personalizada e de precisão.

Além dos pontos já citados, é importante pontuar que a localização de algumas feridas, levando em conta a anatomia do corpo humano, e o perímetro irregular de algumas feridas, pode prejudicar o processo de mensuração manual, dada a

difficuldade em determinar a largura e o comprimento do ferimento, bem como traçar seu perímetro.

Além da mensuração, discorrida nos parágrafos anteriores, outro ponto extremamente relevante é a análise cromática das feridas, que representa um parâmetro fundamental na avaliação clínica, fornecendo indicadores visuais que auxiliam na determinação do estágio do processo cicatricial, presença de infecção e vitalidade dos tecidos


Weigelt et al. (2022) enfatizam que os métodos tradicionais de avaliação de feridas carecem de precisão objetiva, sugerindo que sistemas de análise baseados em características visuais, como a diferenciação de cores no leito da ferida, poderiam proporcionar parâmetros padronizados para identificar diferentes fases de cicatrização, presença de inflamação, tecido desvitalizado e processos necróticos, contribuindo assim para diagnósticos mais acurados e protocolos de tratamento individualizados no contexto da medicina de precisão.

Segundo Mandelbaum, Di Santis e Mandelbaum (2003), o sistema Red/Yellow/Black (RYB) proposto por Cuzzel para classificação de feridas se mostra um instrumento clínico valioso, pois permite categorizar as lesões de acordo com a sua coloração, que geralmente reflete o equilíbrio entre tecidos novos e tecidos necrosados, facilitando assim a tomada de decisão sobre as medidas a serem implementadas no tratamento.

Sendo assim o '*RYB wound classification system*', Sistema de classificação de feridas vermelho, amarelo e preto, destacado por Santos *et al* (2017) como sendo especialmente útil dada a simplicidade em seu uso e interpretação, tem a seguinte descrição com base nos seus três indicativos:

- **Vermelho:** Indica tecido de granulação saudável, caracterizado por boa vascularização e progressão adequada do processo de cicatrização. Representa a fase de regeneração tecidual ativa.
- **Amarelo:** Sinaliza presença de exsudato e tecido desvitalizado. Requer limpeza cuidadosa do ferimento para remover debris celulares e prevenir potenciais infecções.
- **Preto:** Evidência necrose, representando tecido morto que necessita de desbridamento imediato. Sua presença indica interrupção do processo cicatricial e risco de complicações graves.

Figura 03: Representação do Sistema RYB



Fonte: Manual de Padronização de Curativos da Cidade de São Paulo

2.2 Tecnologia e saúde

A integração entre a tecnologia e a medicina tem proporcionado inúmeros benefícios, oferecendo maior rapidez e eficácia para análises médicas e diagnósticos. No contexto da análise de ferimentos, essas tecnologias podem ser a solução para superar as limitações dos métodos manuais, proporcionando resultados precisos, padronizados e rastreáveis.

Esta seção apresenta as principais ferramentas e técnicas aplicadas ao desenvolvimento do sistema de análise de ferimentos. Inicialmente, são abordados as definições e fundamentos da visão computacional, e aplicações conhecidas aplicadas a área da saúde, seguido pela apresentação de algumas técnicas específicas para análise de imagem e cores que viabilizam a implementação.

2.2.1 Trabalhos Correlatos

Na área de análise automatizada de ferimentos cutâneos por meio de imagens, diversos estudos têm sido desenvolvidos nas últimas décadas, utilizando diferentes abordagens tecnológicas para mensurar a área de feridas e identificar cores presentes nos tecidos. Esta seção apresenta uma revisão dos principais trabalhos que se correlacionam com a proposta deste estudo.

A revisão bibliográfica foi conduzida nas bases de dados PubMed/MEDLINE, Scopus, e Portal de Periódicos CAPES. As buscas utilizaram combinações de termos relacionados a feridas, como "wound", "ulcer" e "diabetic foot ulcer", associados a técnicas de processamento de imagens, como "image processing", "computer vision" e "segmentation", empregando operadores booleanos AND para intersecção de termos. Para excluir trabalhos baseados em aprendizado profundo e inteligência artificial, foram aplicados operadores NOT combinados com termos como "deep learning", "machine learning", "neural network" e "CNN". Os principais trabalhos identificados são apresentados a seguir.

Durante o processo de revisão bibliográfica, constatou-se uma escassez de trabalhos recentes fundamentados em técnicas clássicas de visão computacional para análise de feridas. A predominância quase absoluta de abordagens baseadas em inteligência artificial e aprendizado profundo a partir de 2015 evidencia uma lacuna no desenvolvimento e aprimoramento de métodos tradicionais de processamento de imagens.

Cabe mencionar que um dos trabalhos identificados, Goyal et al. (2020), apresenta uma abordagem híbrida que combina técnicas clássicas com deep learning, sendo incluído nesta revisão por propor o descritor Superpixel Colour Descriptor (SPCD) e por ilustrar a transição metodológica observada na área, demonstrando tanto as contribuições das técnicas tradicionais quanto os avanços obtidos com métodos baseados em aprendizado profundo.

- **Sistema Automático de Avaliação de Úlceras do Pé Diabético**

Wang et al. (2016) desenvolveram um sistema colaborativo de avaliação de úlceras do pé diabético composto por um smartphone para captura de imagens e um laptop para processamento, comunicando-se via Wi-Fi em modo peer-to-peer.

O sistema utiliza técnicas clássicas de visão computacional para realizar três funções principais: determinação da área da ferida através de um algoritmo baseado em mean-shift segmentation aprimorado, classificação de tecidos utilizando K-Means clustering no espaço de cor CIE Lab para segmentar tecidos vermelhos (cicatrização), amarelos (infecção/slough) e pretos (necrose) segundo o modelo RYB, e cálculo de um healing score (pontuação de cicatrização) de 0 a 10 que quantifica o status de evolução da ferida comparando visitas subsequentes com a imagem inicial.

Para facilitar a captura de imagens de úlceras localizadas na planta do pé, os autores desenvolveram uma caixa de captura compacta e de baixo custo feita em acrílico branco com iluminação LED consistente. O sistema foi validado clinicamente com 12 pacientes ao longo de um ano na Clínica de Feridas da Universidade de Massachusetts, totalizando 32 imagens de úlceras.

O algoritmo de detecção de área obteve um Matthews Correlation Coefficient (MCC) de 0,68, superior aos 0,45 reportados por trabalhos anteriores, enquanto a validação clínica do healing score através do Krippendorff's Alpha Coefficient (KAC) variou de 0,42 a 0,81 em comparação com as avaliações de três clínicos experientes. O tempo médio de processamento foi de aproximadamente 6 segundos em CPU Intel i5, demonstrando eficiência computacional adequada para aplicação clínica em tempo real e potencial para padronizar a avaliação de feridas e minimizar variações inter e intra-observador.

- **Monitoramento Domiciliar de Feridas com Análise de Espaço de Cor HSV**

Shi et al. (2019) desenvolveram um sistema de monitoramento domiciliar de feridas crônicas utilizando fotografia de smartphone e algoritmos de análise de imagem baseados em técnicas clássicas de visão computacional.

O sistema foi projetado para permitir que pacientes capturem imagens em casa sem equipamentos especiais ou calibração, processando as fotografias através de um algoritmo que realiza três funções principais: transformação do espaço de cor de RGB para **HSV (Hue-Saturation-Value)** com deslocamento do canal Hue para centrar os valores vermelhos, facilitando a análise por histogramas; segmentação de tecidos através de **limiarização (thresholding)** aplicada ao canal Hue para classificar pixels segundo o modelo Black-Yellow-Red em tecido de granulação (vermelho), tecido epitelial (amarelo-vermelho) e necrose (preto); e refinamento da classificação por meio de **operações morfológicas** (erosão seguida de dilatação) para eliminar artefatos e pequenas áreas incorretamente classificadas.

A abordagem foi implementada em Python utilizando a biblioteca OpenCV e validada através do acompanhamento de uma ferida crônica em perna de paciente ao longo de 90 dias, totalizando 119 imagens capturadas com um iPhone 7 Plus. O algoritmo demonstrou robustez em relação a variações nas condições de

iluminação, característica atribuída ao uso do espaço HSV, onde o componente Hue é teoricamente minimamente afetado pela luminância geral da imagem. A análise de composição da ferida revelou tendências distintas das medições de área física, identificando duas fases de cicatrização: uma fase inicial de granulação nos primeiros 30 dias e uma fase subsequente de reepitelização.

Os autores destacam que a análise de composição tecidual fornece informações complementares às métricas tradicionais de dimensão da ferida, sendo especialmente adequada para feridas grandes e não-planares onde medições físicas precisas são desafiadoras, e sugerem como direção futura a integração com tecnologias de câmeras 3D emergentes em smartphones para adicionar capacidade de análise volumétrica ao sistema atual de análise de composição.

- **Reconhecimento de Isquemia e Infecção em Úlceras Diabéticas por Métodos Híbridos**

Goyal et al. (2020) apresentaram o primeiro dataset público para reconhecimento de isquemia e infecção em úlceras do pé diabético (DFU), introduzindo 1459 imagens com ground truth estabelecido por dois especialistas médicos. Os autores investigaram tanto técnicas clássicas de visão computacional quanto deep learning para classificação binária dessas condições críticas que afetam o prognóstico e risco de amputação.

Para a abordagem clássica, os autores propuseram um novo descritor denominado Superpixel Colour Descriptor (SPCD), especificamente desenvolvido para extrair características de cor relevantes para identificação visual de isquemia e infecção. O método inicia com sobre-segmentação da imagem utilizando a técnica SLIC (Simple Linear Iterative Clustering), que realiza otimização de k-means localizada no espaço 5D CIELAB para agrupar pixels baseado em cor e intensidade.

Com $k=200$ superpixels para patches de 256×256 pixels, o valor RGB médio de cada superpixel é calculado e aplicado. Utilizando diferentes valores de threshold, o algoritmo extrai regiões de duas cores particulares de interesse: vermelho (indicativo de inflamação/perfusão) e preto (indicativo de necrose/gangrena), gerando um vetor de características com 10 dimensões que foi combinado com descritores clássicos de textura (LBP, HOG) e cor (RGB, CIELAB) para treinar classificadores tradicionais como BayesNet, Random Forest e Multilayer Perceptron.

Os autores também introduziram uma técnica de Natural Data-Augmentation baseada em localização profunda de feridas usando Faster R-CNN com InceptionResNetV2, que identifica automaticamente a região de interesse (ROI) da úlcera nas imagens completas do pé. Como aproximadamente 92% das úlceras ocupam entre 0-20% da área total da imagem, técnicas convencionais de augmentation (random crop, scale, translation) apresentam risco de perder a ROI. A Natural Data-Augmentation aplica magnificações progressivas centradas na ferida detectada, seguidas de transformações adicionais (rotação, espelhamento, ruído gaussiano, ajustes de contraste), focando o aprendizado nas características salientes da região ulcerada.

Para comparação, foram testados modelos de deep learning com transfer learning (Inception-V3, ResNet50, InceptionResNetV2) e um modelo Ensemble CNN que combina bottleneck features de múltiplas CNNs com classificador SVM. O dataset foi dividido em 70% treino, 10% validação e 20% teste com validação cruzada 5-fold.

Os resultados demonstraram que métodos de deep learning superaram significativamente as abordagens clássicas em ambas as tarefas. Na classificação de isquemia, o Ensemble CNN alcançou 90,3% de acurácia, MCC de 0,807 e AUC de 0,904, enquanto os métodos clássicos obtiveram 78-80% de acurácia. Na classificação de infecção (tarefa mais desafiadora), o Ensemble CNN atingiu 72,7% de acurácia com MCC de 0,454, comparado a 60-64% dos métodos tradicionais. Curiosamente, mesmo com dataset mais desbalanceado, a classificação de isquemia apresentou desempenho superior (acurácia média de 83,3%) em relação à infecção (65,8%), sugerindo que indicadores visuais de isquemia (má perfusão, gangrena) são mais distintivos nas imagens do que os de infecção.

Os autores reconhecem que a classificação de infecção a partir de imagens é particularmente desafiadora porque: (1) as imagens foram capturadas após debridamento, removendo indicadores importantes como exsudato purulento; (2) sinais visuais de inflamação podem ser sutis; (3) o gold standard diagnóstico requer testes sanguíneos e bacteriológicos, não apenas inspeção visual. Eles sugerem que ground truth baseado em testes clínicos objetivos (avaliação vascular para isquemia, exames de sangue para infecção) poderia melhorar significativamente a sensibilidade e especificidade dos algoritmos.

Este trabalho é notável por representar a transição entre métodos clássicos e deep learning na análise de úlceras diabéticas, propondo técnicas clássicas inovadoras (SPCD, Natural Data-Augmentation) enquanto demonstra empiricamente a superioridade do deep learning para este problema específico. O dataset público disponibilizado constitui importante contribuição para pesquisas futuras na área.

- **Sistema APD Skin Monitoring para Monitoramento de Feridas**

Wu et al. (2019) desenvolveram um aplicativo móvel chamado APD Skin Monitoring, que utiliza técnicas de processamento de imagem baseadas na biblioteca OpenCV para análise automatizada de feridas cutâneas.

O sistema permite o cálculo automático da área da ferida através de fotografias convencionais que incluem uma moeda como referência de escala, além de oferecer funcionalidades como análise colorimétrica através de histogramas, sobreposição de imagens para comparação visual e geração de gráficos para acompanhamento da evolução da cicatrização ao longo do tempo.

Para detecção da moeda de referência, o algoritmo de detecção de círculos Hough da biblioteca OpenCV foi otimizado através da incorporação de transformação para o espaço de cor HSV (Hue-Saturation-Value), processando apenas os canais de Saturação e Valor para melhorar o contraste e facilitar a detecção, enquanto o canal Hue foi eliminado por não ser crítico para essa função.

Os autores compararam duas abordagens para detecção de feridas: o algoritmo GrabCut e um método baseado em limiarização de cores. O GrabCut, embora capaz de realizar segmentação razoável, mostrou-se lento (tempo médio de 23,2 segundos) e menos preciso (2/4 imagens segmentadas corretamente), além de exigir interação do usuário para definir um retângulo ao redor da ferida. Em contraste, o método de limiarização por cor, utilizando o intervalo BGR de (0, 0, 120) a (100, 100, 255) para separar pixels correspondentes à ferida do fundo da imagem, seguido de detecção de contornos, demonstrou maior eficiência com tempo médio de processamento de apenas 1,70 segundos e precisão de 4/4 imagens corretamente segmentadas.

Optando pelo segundo método devido à sua maior eficiência e precisão na identificação do contorno da lesão, os autores implementaram funcionalidades adicionais como análise de histograma de cores para detectar mudanças

características como presença de sangue, crostas ou pus, e sobreposição de imagens ao longo do tempo usando a moeda como referência para redimensionamento e padronização.

O sistema foi validado através de um estudo de caso com imagens de ferida de um voluntário ao longo de aproximadamente três meses, demonstrando o potencial dessa tecnologia para empoderar pacientes no automonitoramento de feridas e reduzir a necessidade de visitas clínicas frequentes, disponibilizando o aplicativo gratuitamente nas lojas Google Play e App Store.

- **Segmentação de Feridas Crônicas por Clustering em Espaço de Cor Otimizado**

Yadav et al. (2013) desenvolveram uma metodologia para segmentação automática de áreas de feridas crônicas através de técnicas de clustering aplicadas em espaços de cor criteriosamente selecionados. O sistema proposto processa imagens capturadas por câmeras digitais convencionais através de um pipeline de pré-processamento que inclui correção de cor pelo método combinado de Gray World e Retinex, redução de ruído por filtro mediano 5×5 para eliminação de ruído sal causado por reflexos em exsudatos, e homogeneização de cores por difusão anisotrópica baseada no filtro de Perona-Malik que suaviza regiões preservando bordas.

Um aspecto distintivo deste trabalho é a análise comparativa sistemática de quinze espaços de cor (RGB, HSI, XYZ, Lab, Luv, LCH, HSV, HSL, YUV, YIQ, CAT02 LMS, YCbCr, JPEG-YCbCr, YDbDr e YPbPr) para identificar os canais com maior contraste entre a região da ferida e o tecido circundante. O critério de seleção baseou-se no cálculo do contraste médio absoluto entre as intensidades médias dos pixels da ferida e do fundo em cada canal. Os resultados demonstraram que os canais de cromaticidade Db e Dr do espaço de cor YDbDr, utilizado no codec JPEG 2000, proporcionaram contraste superior (0.242 e 0.261 respectivamente), aproximadamente o dobro dos valores obtidos nos espaços RGB e HSI tradicionalmente empregados para segmentação de feridas.

A segmentação propriamente dita foi realizada através de dois algoritmos de clustering não supervisionado: K-means e Fuzzy C-means (FCM). O K-means particiona os dados em k clusters baseando-se na minimização da distância

euclidiana entre pixels e centróides, atribuindo cada pixel exclusivamente a um único cluster. O FCM, por sua vez, implementa uma abordagem fuzzy onde cada pixel recebe um grau de pertinência a múltiplos clusters, sendo mais adequado para dados com sobreposição de características, como é o caso de feridas com composição tecidual heterogênea. O parâmetro de fuzziness m foi configurado como 2 para controlar o grau de sobreposição entre clusters.

O sistema foi validado em 77 imagens digitais de cinco tipos diferentes de feridas crônicas (úlceras de pressão, úlceras diabéticas, úlceras venosas, úlceras malignas e pioderma gangrenoso) provenientes da base de dados médica Medetec, utilizando segmentação manual por dermatologista como padrão-ouro. As métricas de avaliação incluíram acurácia de segmentação (SA), valor preditivo positivo (PPV) e sensibilidade. Os resultados mostraram que o algoritmo K-means obteve acurácia média de 74,39% no canal Dr e 73,76% no canal Db, enquanto o FCM alcançou 72,55% no canal Dr e 75,23% no canal Db, sendo este último o melhor resultado geral, superando inclusive o algoritmo JSEG reportado por outros autores com 73,1% de acurácia. A análise por tipo de ferida revelou as maiores acurácias para úlceras venosas (82,39% com K-means e 84,20% com FCM no canal Db), enquanto as menores foram observadas em úlceras malignas e pioderma gangrenoso.

A seleção do canal Db como o mais adequado para segmentação foi justificada não apenas pelo contraste elevado, mas principalmente pela menor variabilidade de intensidades (desvio padrão de 0,108 para fundo e 0,127 para ferida), o que resulta em valores de PPV e sensibilidade mais equilibrados no FCM, indicando menor sobre-segmentação e sub-segmentação simultâneas. Os autores concluem que a abordagem proposta, combinando otimização de espaço de cor com algoritmos de clustering clássicos, oferece uma ferramenta computacional objetiva, confiável e de baixo custo para segmentação e medição de área de feridas, facilitando a avaliação precisa do processo de cicatrização e podendo ser estendida para outras aplicações similares como segmentação de tecidos em queimaduras ou tumores de pele.

- **Avaliação Automatizada de Área de Feridas Baseada em Imagens com K-Means Clustering e Código QR de Referência**

Li et al. (2025) desenvolveram um sistema automatizado para avaliação objetiva de área de feridas em ambiente ambulatorial, utilizando técnicas clássicas de visão computacional combinadas com o código QR de identificação do paciente como referência espacial.

O método proposto aborda o desafio clínico da variabilidade nas medições de feridas causada por diferentes profissionais de saúde, momentos de avaliação e distâncias de captura fotográfica, que comprometem a precisão e reprodutibilidade das medições tradicionais realizadas com filme transparente Opsite Flexigrid.

O sistema opera em duas etapas principais: detecção do código QR para estabelecimento de escala e segmentação da ferida por clustering. Para detecção do QR code, a imagem capturada por smartphone é convertida para escala de cinza e submetida a transformação binária por inversão com limiarização automática pelo método de Otsu, que seleciona o threshold ótimo automaticamente para criar uma imagem binária onde cada pixel recebe valor 1 (branco) ou 0 (preto) conforme sua intensidade.

Em seguida, aplicam-se operações morfológicas de dilatação seguida de erosão, que constituem uma operação de fechamento para preencher pequenos gaps, eliminar ruído e tornar as bordas do QR code mais distintas. Objetos conectados às bordas da imagem são removidos para isolar o QR code, e um filtro de área retém apenas objetos dentro de um intervalo de tamanho específico, permitindo identificar e calcular a área em pixels do código QR através da contagem de pixels brancos.

Para segmentação da ferida, a imagem é convertida do espaço RGB para o espaço de cor $L^*A^*B^*$, que separa informações de luminância (brilho) e cromaticidade (cor), facilitando a segmentação precisa. O algoritmo K-means clustering é então aplicado no espaço $L^*A^*B^*$ para agrupar pixels da imagem em clusters distintos baseados em similaridade de cor, identificando o cluster correspondente à região da ferida e gerando uma máscara binária.

Esta máscara é refinada através de operações morfológicas de abertura para remover pequenos objetos espúrios e preenchimento de buracos, resultando em uma representação binária limpa da ferida. A função *bwboundaries* do MATLAB é utilizada para traçar os pontos de contorno da região segmentada, e a área final é calculada contando os pixels não-pretos dentro do cluster da ferida.

A área real da ferida em centímetros quadrados é calculada pela fórmula: $\text{Área real} = (\text{Área em pixels da ferida} \times \text{Área real do QR code}) / \text{Área em pixels do QR code}$, eliminando a necessidade de controlar rigorosamente a distância de captura fotográfica, desde que o código QR e a ferida estejam visíveis na mesma imagem e a fotografia seja tomada perpendicularmente à superfície da ferida.

O sistema foi validado em 40 pacientes com feridas cutâneas visíveis em ambiente ambulatorial, capturando três fotos de cada ferida em alturas aleatórias usando smartphones diversos (iPhone, Samsung, Asus). A precisão do algoritmo foi verificada utilizando uma moeda de 1 centavo de dólar (área real de 2.8488 cm²) como padrão de referência, obtendo área calculada de 2.8366 cm², representando uma diferença de apenas 0,4%.

Testes estatísticos confirmaram a confiabilidade do método: testes t pareados entre as três capturas fotográficas aleatórias produziram valores p de 0.370, 0.179 e 0.547, todos superiores a 0.05 e indicando ausência de diferenças significativas; correlações de Pearson superiores a 0.99 entre todas as combinações de fotos demonstraram consistência quase perfeita; e análise de variância (ANOVA) com $F=0.0049$ e $p=0.9951$ confirmou que as três medições podem ser consideradas equivalentes independentemente da altura de captura.

Os autores destacam como principais vantagens do sistema: eliminação da subjetividade das medições manuais, garantia de reprodutibilidade independente do operador, robustez a variações na distância de captura fotográfica, utilização de código QR já presente no sistema de identificação de pacientes (sem necessidade de elementos adicionais), e adequação ao fluxo de trabalho clínico acelerado de ambulatorios onde não é viável garantir protocolos fotográficos rigorosos.

O método demonstra potencial significativo para monitoramento remoto de feridas via telemedicina, permitindo que pacientes capturem imagens em domicílio e as transmitam para avaliação clínica à distância, especialmente relevante para feridas crônicas como úlceras diabéticas e úlceras de pressão.

2.2.2 Visão Computacional

A Visão Computacional é um conceito antigo. As primeiras menções a esse termo ocorreram por volta de 1950, e em 1982 Ballard e Brown publicaram o livro

Computer Vision. Segundo os autores, a visão computacional é a ciência que permite que máquinas "enxerguem".

Nesse contexto, segundo Neves, Neto e Gonzaga (2012), a visão computacional, busca integrar processamento digital de imagens e inteligência artificial, desenvolvendo algoritmos capazes de interpretar de forma inteligente o conteúdo visual de imagens. Em complemento, o “objetivo principal da visão computacional é fazer com que as máquinas vejam o mundo da mesma forma que os humanos” (Bhatt *et al.*, 2020).

Embora o seu objetivo principal permaneça o mesmo desde os primeiros trabalhos, a capacidade de interpretação evoluiu significativamente. Hoje a visão computacional permite uma interpretação visual mais complexa, com sistemas capazes de reconhecer objetos, compreender contextos e até antecipar eventos a partir de dados visuais, e grande parte desses avanços se deve à evolução da Inteligência Artificial.

Mesmo que, como citado no parágrafo anterior, os recentes avanços da visão computacional estejam diretamente ligados a Inteligência Artificial, o presente trabalho tem em foco uma abordagem mais tradicional, baseada em técnicas clássicas de processamento de imagem, implementadas por meio da biblioteca OpenCV, sem a necessidade de utilizar modelos de IA.

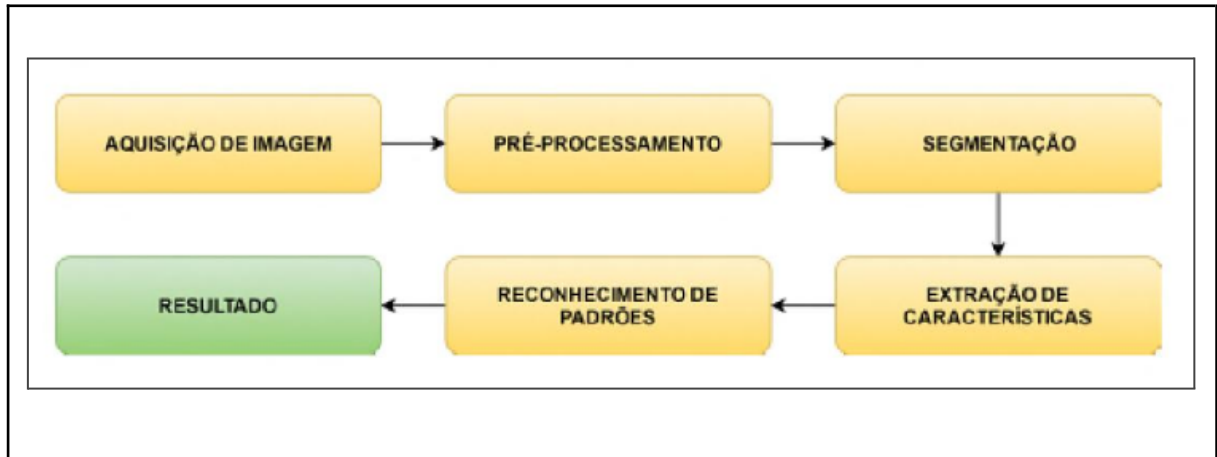
Segundo Kundu (2024), às funcionalidades mais comuns em sistemas implementados com essa tecnologia são:

- Aquisição de Imagem: Processo de adquirir uma imagem a partir de sensores de câmeras.
- Pré-Processamento: Processo realizado antes de obter as informações da imagem, visando facilitar o processamento.
- Extração de Características: Obtenção de informações que compõem a imagem, como textura e formato.
- Detecção e Segmentação: Processo realizado para destacar regiões importantes da imagem
- Processamento de alto nível: Processo que inclui a validação dos dados obtidos sobre as imagens processadas.

A *figura 03* ilustra o fluxo base de um sistema voltado a visão computacional, algumas aplicações reais desta tecnologia incluem: controle de qualidade, inspeção

visual de equipamentos de segurança, análise de movimentos, monitoramento de automóveis, e reconhecimento facial, dentre outros.

Figura 03: Fluxo comum de um sistema de Visão Computacional



Fonte: Introdução à Visão Computacional: Uma abordagem prática com Python e OpenCV


2.2.3. Visão Computacional na Saúde

Um dos maiores desafios da área médica tem sido como adquirir, processar e exibir dados sobre o corpo, de modo que a informação possa ser visualizada, interpretada e utilizada. Na maior parte dos casos o uso de imagens é a abordagem mais eficiente para enfrentar esse desafio (Silva , Patrocínio , Schiabel. 2019).

Por esse motivo, segundo Sabry (2024), o processamento de imagens médicas é uma das áreas de aplicação mais expressivas e significativas atualmente, complementado por Tavares *et al* (2024), que salienta como essa tecnologia tem se consolidado como essencial.

Barelli (2018), ressalta que sistemas de visão computacional têm sido utilizados para detectar anomalias em exames como: tomografias, ressonâncias, ultrassons, etc. Em paralelo a outro campo que vem ganhando espaço recentemente, de acordo com Tavares *et al* (2024), o monitoramento de pacientes em ambiente hospitalar, nesse caso o sistema é utilizado para rastrear movimentos, detectar quedas, e monitorar sinais vitais.

Figura 04: Tumor cerebral detectado através de visão computacional.



Fonte: Introdução à Visão Computacional: Uma abordagem prática com Python e OpenCV

Existem também funcionalidades mais críticas sendo desenvolvidas com essa tecnologia, como as intervenções cirúrgicas assistidas onde sistemas utilizam algoritmos avançados para guiar instrumentos robóticos com alta precisão durante procedimentos (Tavares *et al* ,2024).

2.2.4. Open Source Computer Vision

O OpenCV (Open Source Computer Vision) (opencv.org), como destacado por Delai e Coelho, é "um conjunto de ferramentas de programação para desenvolvimento de aplicações com Visão" . A ferramenta é completamente open-source e distribuída gratuitamente, aberta a colaborações de qualquer indivíduo.

A biblioteca apresenta uma diversidade enorme de módulos e por esse motivo é dividida em grupos específicos de funções. Conforme Marengoni e Stringhini (2009), o OpenCV está organizado em cinco grupos principais: Processamento de imagens; Análise estrutural; Análise de movimento e rastreamento de objetos; Reconhecimento de padrões; e Calibração de câmera e reconstrução 3D.

Para o presente trabalho, o foco vai para o processamento de imagens, que nesse caso será o principal módulo do sistema. O OpenCV fornece ferramentas essenciais para manipular e preparar imagens para análises mais complexas (Marengoni e Stringhini,2009). Por esse motivo foi a ferramenta escolhida para a implementação da solução proposta.

A grande vantagem do OpenCV é a sua capacidade de processamento de imagens em tempo real, além da sua modularidade, e de suas funções pré-codificadas, que permitem o desenvolvimento e implantação de soluções personalizadas de forma rápida e eficiente.

2.2.5. Técnicas de Visão computacional para análise de imagens

A análise de imagens de ferimentos cutâneos por meio da visão computacional requer a aplicação de técnicas específicas de processamento e segmentação que permitam a identificação e quantificação precisa das lesões. Este trabalho utiliza uma abordagem baseada em contornos ativos (Active Contour) precedida por etapas de pré-processamento essenciais.

Figura 05: Imagem original de lesão por pioderma gangrenoso utilizada para demonstração do método de segmentação.



Fonte: Salviano et al. (2025)

A delimitação manual da *região de interesse* (ROI) é uma prática comum em aplicações de segmentação médica, permitindo ao usuário definir a área aproximada da lesão e reduzir o espaço de processamento. Esta abordagem elimina ruídos provenientes de regiões distantes e melhora a eficiência computacional do algoritmo. No OpenCV, a função `selectROI` permite essa seleção interativa:

```
import cv2


roi = cv2.selectROI("Selecione a Área de Interesse", imagem_original,

                    fromCenter=False, showCrosshair=True)

x, y, w, h = roi

roi_imagem = imagem_original[y:y+h, x:x+w]
```

Figura 06: Região de interesse (ROI) delimitada manualmente sobre a lesão.



Fonte: Adaptado de Salviano et al. (2025)

O pré-processamento constitui etapa fundamental para melhorar a qualidade da imagem antes da segmentação. Segundo Gonzalez e Woods (2018), essa fase visa reduzir ruídos e realçar características importantes da imagem. A *conversão para escala de cinza* transforma a imagem colorida em uma representação monocromática através da função `cvtColor` do OpenCV, simplificando o processamento ao reduzir a dimensionalidade dos dados de três canais (BGR) para um único canal de intensidade:

```
imagem_cinza = cv2.cvtColor(roi_imagem, cv2.COLOR_BGR2GRAY)
```

Figura 07: Imagem convertida para escala de cinza.



Fonte: Adaptado de Salviano et al. (2025)

A *suavização Gaussiana* aplica um filtro de convolução que reduz ruídos de alta frequência enquanto preserva as bordas principais. No OpenCV, a função `GaussianBlur` com kernel 5x5 realiza esta operação, preparando a imagem para a segmentação subsequente:

```
imagem_suavizada = cv2.GaussianBlur(imagem_cinza, (5, 5), 0)
```

Figura 08: Imagem após aplicação do filtro Gaussiano (kernel 5x5).



Fonte: Adaptado de Salviano et al. (2025)

Os *contornos ativos*, também conhecidos como *Snakes*, são curvas deformáveis que se ajustam aos contornos de objetos em imagens sob a influência

de forças internas e externas (Kass et al., 1988). Este método, implementado na biblioteca scikit-image através da função `active_contour`, baseia-se na minimização de uma função de energia que combina características da imagem com restrições de suavidade do contorno.

Para a aplicação do Active Contour, é necessário definir um contorno inicial próximo ao objeto de interesse. Neste trabalho, utiliza-se uma elipse parametrizada com base nas dimensões da ROI selecionada, posicionada no centro da região e dimensionada para cobrir aproximadamente 80% da área:

```
import numpy as np

center_x = w // 2
center_y = h // 2

raio_x = (w / 2) * 0.8
raio_y = (h / 2) * 0.8

s = np.linspace(0, 2 * np.pi, 400)
r = center_y + raio_y * np.sin(s)
c = center_x + raio_x * np.cos(s)

init = np.array([r, c]).T
```

Figura 09: Contorno inicial (elipse) para o algoritmo Active Contour.



Fonte: Adaptado de Salviano et al. (2025)

Antes da aplicação do Snake, a imagem passa por um *filtro Gaussiano adicional* através da função `gaussian` da biblioteca `scikit-image`, que otimiza a convergência do algoritmo ao suavizar gradientes de intensidade. As forças internas do Active Contour são controladas pelos parâmetros `alpha` (elasticidade) e `beta` (rigidez), que regulam a suavidade e continuidade da curva. As forças externas são derivadas do gradiente de intensidade da imagem, atraindo os pontos do contorno em direção às bordas detectadas. O parâmetro `gamma` controla a taxa de convergência do algoritmo:

```
from skimage.filters import gaussian
from skimage.segmentation import active_contour

img_gaussian = gaussian(imagem_cinza, 3, preserve_range=False)
snake = active_contour(img_gaussian,

                        init,

                        alpha=0.015, # Elasticidade

                        beta=10,      # Rigidez

                        gamma=0.001) # Taxa de convergência
```

Figura 10: Contorno final após convergência do Active Contour.



Fonte: Adaptado de Salviano et al. (2025)

Após a convergência do Snake, o contorno resultante é convertido em uma *máscara binária* através da função `fillPoly` do OpenCV, que preenche a região delimitada pelo contorno com pixels brancos (valor 255) sobre um fundo preto (valor 0):


```
# Conversão do Snake para formato OpenCV
snake_contour = snake.astype(np.int32)

snake_contour = snake_contour[:, [1, 0]] # Inverter coordenadas (row,col)
-> (x,y)

# Criação da máscara binária
mascara_snake = np.zeros_like(imagem_cinza)

cv2.fillPoly(mascara_snake, [snake_contour], 255)
```

Figura 11: Máscara binária da região segmentada.



Fonte: Adaptado de Salviano et al. (2025)

Esta máscara é então aplicada à imagem original da ROI através de uma *operação bitwise AND*, isolando completamente o ferimento do restante da imagem:

```
imagem_segmentada = cv2.bitwise_and(roi_imagem, roi_imagem,  
mask=mascara_snake)
```

Figura 12: Ferimento isolado após aplicação da máscara.



Fonte: Adaptado de Salviano et al. (2025)

Com a segmentação concluída, são calculadas métricas quantitativas através das funções `contourArea` e `arcLength` do OpenCV, incluindo área em pixels quadrados, perímetro, circularidade (relação entre área e perímetro) e solidez (razão entre a área do contorno e sua envoltória convexa):

```
# Cálculo de métricas  
  
area = cv2.contourArea(snake_contour)  
  
perimetro = cv2.arcLength(snake_contour, True)
```



```
x_c, y_c, w_c, h_c = cv2.boundingRect(snake_contour)

# Circularidade (1.0 = círculo perfeito)
circularidade = (4 * np.pi * area) / (perimetro ** 2) if perimetro > 0 else 0

# Solidez (convexidade)
hull = cv2.convexHull(snake_contour)
area_convexa = cv2.contourArea(hull)
solidez = area / area_convexa if area_convexa > 0 else 0
```

Estas medidas fornecem informações objetivas para acompanhamento clínico da evolução da lesão.

Figura 13: Visualização final com overlay do contorno detectado.



Fonte: Adaptado de Salviano et al. (2025)

A abordagem baseada em Active Contour apresenta vantagens significativas em relação a métodos tradicionais de segmentação por limiarização ou detecção de

bordas, pois se adapta a contornos irregulares, é robusta a variações de iluminação e não depende de limiares fixos ou detecção prévia de características específicas da imagem (Xu e Prince, 1998).

2.2.6. Técnicas de Visão Computacional para Análise de Cores

A análise cromática constitui uma etapa fundamental na caracterização de ferimentos, permitindo identificar, quantificar e interpretar as cores presentes na região lesionada. Essas informações são relevantes para avaliação do estágio de cicatrização, detecção de sinais de infecção e monitoramento da evolução do tratamento. Nesse contexto, o sistema Red/Yellow/Black (RYB) proposto por Cuzzel para classificação de feridas se mostra um instrumento clínico valioso, pois permite categorizar as lesões de acordo com a sua coloração, que geralmente reflete o equilíbrio entre tecidos novos e tecidos necrosados (MANDELBAUM; DI SANTIS; MANDELBAUM, 2003). As técnicas de visão computacional aplicadas à análise de cores envolvem conversão entre espaços de cores, segmentação cromática e algoritmos de clustering para identificação de cores dominantes.

Antes de iniciar a análise cromática, é necessário isolar a região de interesse e remover elementos que possam interferir nos resultados, como fundos escuros provenientes de etapas anteriores de segmentação. A remoção de pixels indesejados pode ser realizada através de threshold, onde pixels com intensidade abaixo de um limiar são identificados e substituídos. O código abaixo exemplifica essa operação:

```

gray = cv2.cvtColor(imagem, cv2.COLOR_BGR2GRAY)

_, mask = cv2.threshold(gray, 10, 255, cv2.THRESH_BINARY)

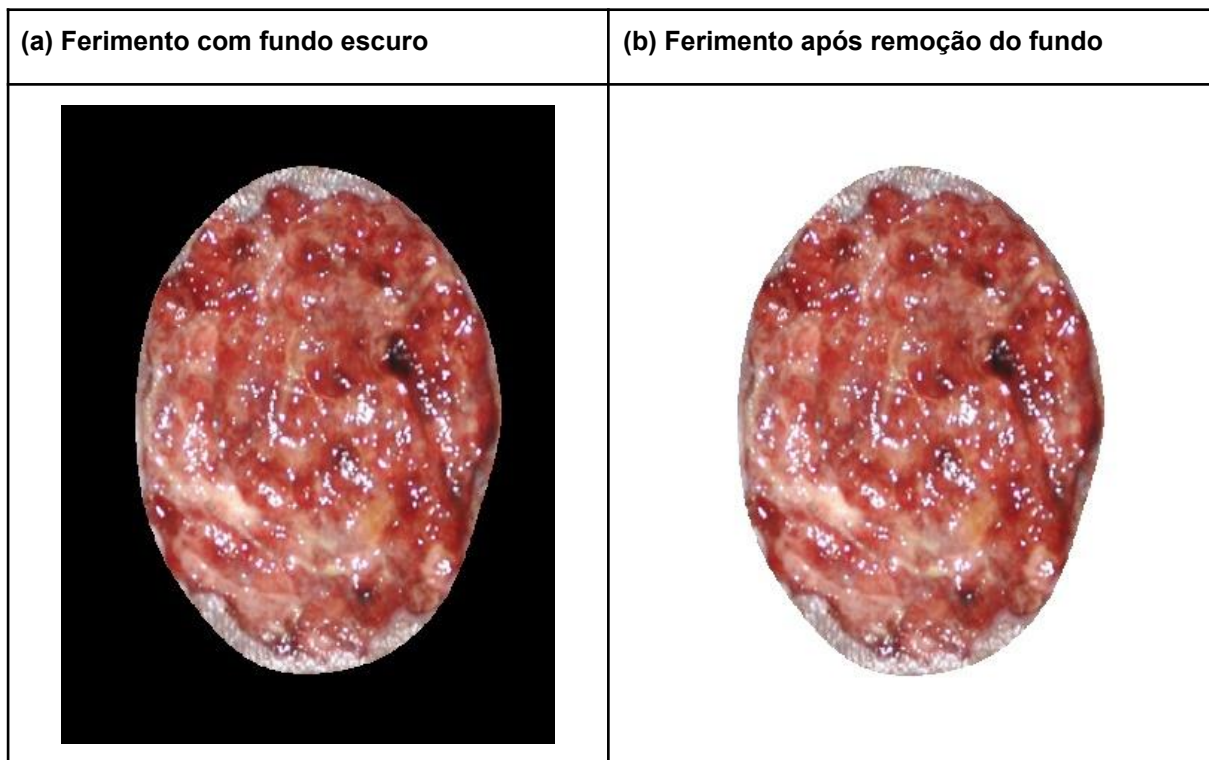
mask_inv = cv2.bitwise_not(mask)

img_sem_fundo = imagem.copy()
img_sem_fundo[mask_inv == 255] = [255, 255, 255]

```

Essa abordagem garante que apenas os pixels pertencentes ao ferimento sejam considerados nas análises subsequentes. A Figura 14 ilustra o resultado da remoção de fundo.

Figura 14: Remoção do fundo da imagem



Fonte: Adaptado de Salviano et al. (2025)

O OpenCV suporta múltiplos espaços de cores, cada um com características específicas que facilitam diferentes tipos de análise. Os espaços mais importantes para análise cromática de ferimentos são o HSV (Hue, Saturation, Value) e o Lab (Lightness, a, b). O espaço HSV é intuitivo para segmentação por cor, por que separa a informação cromática (matiz) da iluminação da imagem, enquanto o Lab foi projetado para aproximar a percepção visual humana de cores.

A conversão entre espaços é realizada através da função `cv2.cvtColor()`, e os canais individuais podem ser separados com `cv2.split()`:

```
hsv = cv2.cvtColor(imagem, cv2.COLOR_BGR2HSV)


h, s, v = cv2.split(hsv)

lab = cv2.cvtColor(imagem, cv2.COLOR_BGR2LAB)
l, a, b = cv2.split(lab)
```


Os canais H (matiz) e S (saturação) do espaço HSV permitem identificar características como áreas de maior pigmentação e regiões saturadas. O canal V (valor/brilho) auxilia na detecção de variações de luminosidade que podem sugerir presença de exsudato. No espaço Lab, o canal L representa a luminância, enquanto os canais A (eixo verde-vermelho) e B (eixo azul-amarelo) capturam informações cromáticas independentes da iluminação. A Figura 15 apresenta exemplos dos seis canais extraídos.

Figura 15: Canais de cores extraídos

| | |
|-------|-------|
| (a) H | (b) S |
|-------|-------|




(c) V




(d) L



(e) A



(f) B



Fonte: Adaptado de Salviano et al. (2025)

A identificação de cores dominantes em uma imagem pode ser realizada através do algoritmo de clustering K-Means, que agrupa pixels similares em clusters baseado em suas características cromáticas. O algoritmo particiona o conjunto de pixels em K grupos, onde cada grupo é representado por seu centroide (cor média).

Para aplicar o K-Means, a imagem deve ser preparada convertendo-a em um vetor bidimensional onde cada linha representa um pixel com seus três valores RGB:

```
from sklearn.cluster import KMeans

pixels = imagem.reshape(imagem.shape[0] * imagem.shape[1], 3)

kmeans = KMeans(n_clusters=5, random_state=42, n_init=10)
labels = kmeans.fit_predict(pixels)

cores_dominantes = kmeans.cluster_centers_
```

Após a execução, cada pixel recebe um rótulo indicando a qual cluster pertence, e os centros dos clusters representam as cores dominantes. A contagem de pixels em cada cluster permite calcular a distribuição percentual de cada cor na

região analisada. É importante filtrar cores indesejadas, como branco residual de remoções de fundo:

```
from collections import Counter

contagem = Counter(labels)

cores_filtradas = []
for cor in cores_dominantes:
    if not all(componente >= 250 for componente in cor):
        cores_filtradas.append(cor)
```

A distribuição de cores pode ser visualizada através de diferentes representações gráficas. Uma paleta de cores pode ser criada desenhando retângulos coloridos com os valores dos clusters identificados:

```
def rgb_to_hex(rgb):
    return "#{:02x}{:02x}{:02x}".format(int(rgb[0]), int(rgb[1]),
int(rgb[2]))

altura_barra = 80
paleta = np.ones((len(cores) * altura_barra, 600, 3), dtype=np.uint8) * 255

for i, (cor, percentual) in enumerate(zip(cores, percentuais)):
    y = i * altura_barra
    bgr = (int(cor[2]), int(cor[1]), int(cor[0])) # RGB para BGR
    cv2.rectangle(paleta, (0, y), (420, y + altura_barra), bgr, -1)

    texto = f"{rgb_to_hex(cor)}: {percentual:.1f}%"
    cv2.putText(paleta, texto, (10, y + 45), cv2.FONT_HERSHEY_SIMPLEX,
0.7, (255, 255, 255), 2)
```


Alternativamente, gráficos de pizza podem ser gerados utilizando bibliotecas como Matplotlib, possibilitando uma visualização intuitiva dos percentuais de cada cor:

```
import matplotlib.pyplot as plt

plt.figure(figsize=(10, 8))
cores_hex = [rgb_to_hex(cor) for cor in cores_dominantes]
plt.pie(percentuais, labels=cores_hex, colors=cores_hex, autopct='%1.1f%%')
plt.title('Distribuição de Cores')
plt.savefig('grafico_cores.png')
```


A Figura 16 ilustra exemplos de paletas de cores e gráficos de distribuição.

Figura 16: Visualização da distribuição cromática



Fonte: Elaborado pelo autor


Para visualizar a distribuição espacial das cores identificadas, pode-se reconstruir a imagem substituindo cada pixel pela cor do centro do cluster ao qual pertence, gerando uma versão visual da quantificação das cores identificadas:

```
imagem_quantizada = cores_dominantes[labels]
imagem_quantizada = imagem_quantizada.reshape(imagem.shape)
imagem_quantizada = imagem_quantizada.astype(np.uint8)
```

Esse mapa de cores permite identificar visualmente regiões homogêneas e localizar áreas com características cromáticas específicas, como bordas avermelhadas indicando inflamação ou regiões amareladas sugerindo presença de tecido necrótico. A Figura 17 compara a imagem original com o mapa de cores resultante.

Figura 17: Visualização da quantificação de cores

| (a) Imagem original | (b) Mapa de distribuição espacial das cores dominantes |
|---------------------|--|
|---------------------|--|



Fonte: Adaptado de Salviano et al. (2025)

As técnicas apresentadas possibilitam uma análise cromática completa e quantitativa de ferimentos, fornecendo dados objetivos que podem ser utilizados para monitoramento longitudinal, comparação entre diferentes casos e alimentação de algoritmos de aprendizado de máquina para classificação automática do estágio de cicatrização.

3. Metodologia

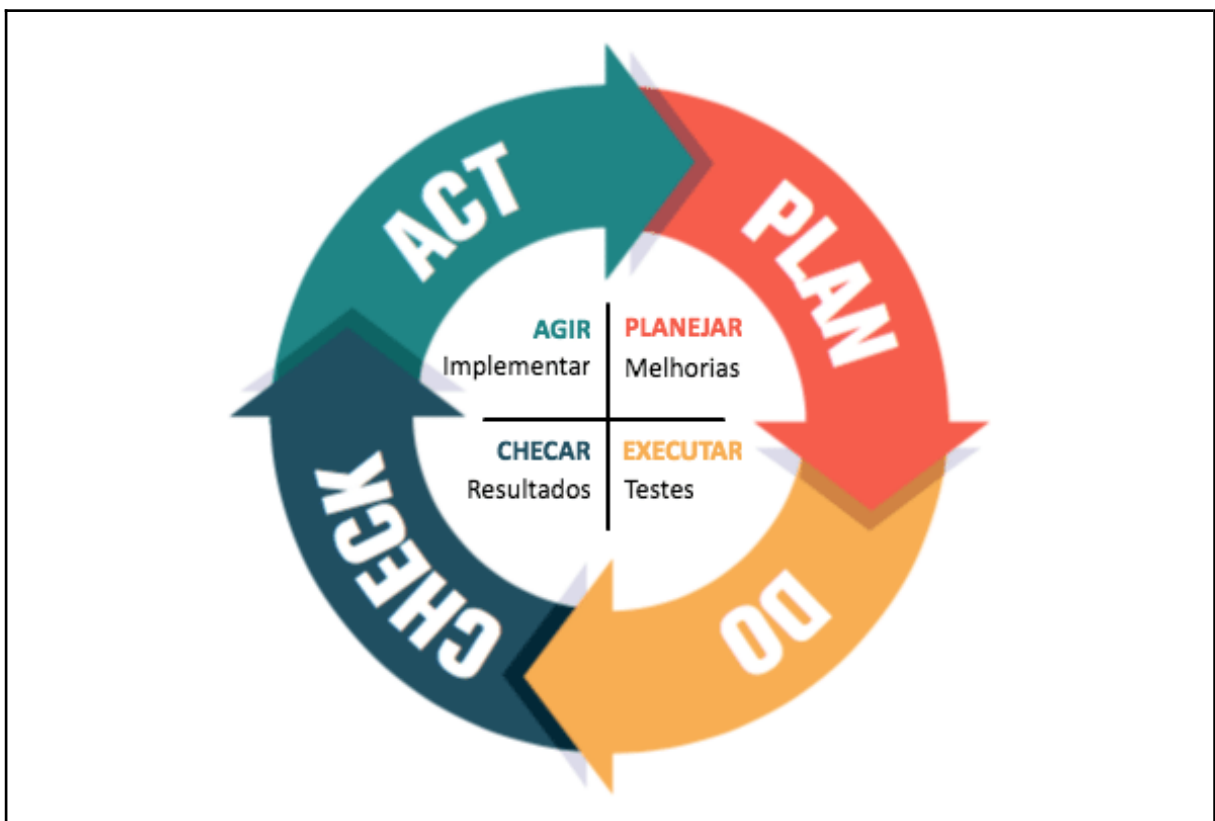
Este trabalho adota uma abordagem de desenvolvimento ágil e iterativo, fundamentada na aplicação de dois ciclos PDCA (Plan-Do-Check-Act) para garantir a qualidade e eficácia da solução proposta. Dentro da fase de execução de cada ciclo foi utilizado o PDSII (Processo Iterativo e Incremental de Desenvolvimento de Software).

3.1 PDCA

O PDCA é uma filosofia organizacional aplicada à cultura de melhoria contínua, representando uma intersecção entre o método científico e ações específicas de resolução de problemas. O ciclo foi criado na década de 30 por Walter A. Shewhart, mas foi consagrado 20 anos depois por William Edwards Deming, por esse motivo a metodologia também pode ser chamada de Ciclo de Shewhart ou Ciclo de Deming (NGUYEN et al., 2020).

O principal objetivo desse método é ter maior controle dos processos para elevar a qualidade dos mesmos de forma contínua, ele segue quatro etapas bem definidas para a sua implementação: Plan, Do, Check e Act, as iniciais de cada etapa formam o nome do ciclo.

Figura 18: Ilustração do Ciclo PDCA



Fonte: Ciclo PDCA: 4 passos para melhorar processos

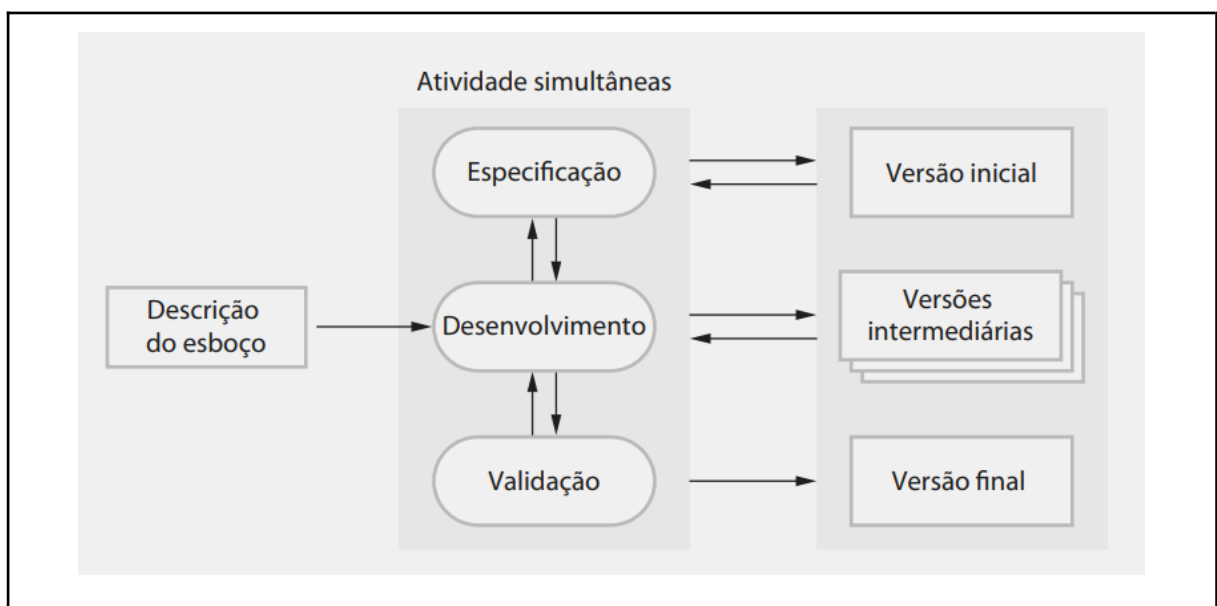
A etapa **Plan** (Planejar) consiste no planejamento das atividades e definição de metas, a etapa **Do** (Executar) representa a implementação das tarefas conforme o planejamento, a etapa **Check** (Verificar) é caracterizada pelo monitoramento e

avaliação dos resultados, e a etapa **Act** (Agir) consiste na implementação de ações corretivas para os problemas identificados (Oliveira et al, 2022).

3.2 PDSII

O desenvolvimento iterativo e incremental é uma abordagem consolidada na engenharia de software que combina ciclos de refinamento sucessivos (iterativo) com entregas parciais e funcionais (incremental). Segundo Sommerville (2011), o modelo incremental reduz custos técnicos de mudanças, facilita o gerenciamento de riscos e permite entregas mais eficazes ao dividir o sistema em módulos funcionais menores. Pressman e Maxim (2016) complementam destacando que essa metodologia permite que o software evolua através de versões progressivamente mais completas, possibilitando ajustes contínuos baseados em testes.

Figura 19: Ilustração do PDSII



Fonte: Engenharia de software. Sommerville, Ian. 2011

Esta abordagem mostrou-se particularmente adequada para o presente trabalho, considerando que o desenvolvimento do Bio-CV exigiu inúmeros testes com diferentes algoritmos e funções da biblioteca OpenCV. Foi necessário testar múltiplas técnicas de detecção de bordas, segmentação e análise cromática para identificar quais se encaixariam melhor ao problema de análise de ferimentos cutâneos. O desenvolvimento iterativo permitiu avaliar cada solução implementada, descartar abordagens ineficazes e evoluir continuamente os algoritmos.

A aplicação prática do desenvolvimento iterativo e incremental ocorreu especificamente durante a fase DO (Executar) de ambos os ciclos PDCA. Em cada iteração, um módulo funcional era implementado, testado individualmente e refinado antes de avançar para o próximo .

3.2 Primeiro Ciclo PDCA - Desenvolvimento Dos Algoritmos

O Quadro 01 apresenta a distribuição das atividades desenvolvidas no primeiro ciclo PDCA, focado em desenvolver os algoritmos base do Bio-CV, a aplicação da metodologia foi essencial para um desenvolvimento controlado e um resultado de qualidade

Quadro 01: Distribuição das atividades do Primeiro Ciclo PDCA - Algoritmos

| Etapa | Atividades Realizadas |
|-------------------|--|
| Plan (planejar) | <ul style="list-style-type: none">• Definir requisitos funcionais dos algoritmos de processamento• Especificar tecnologias (Python, OpenCV)• Projetar arquitetura dos módulos (detecção, área, cores)• Definir dataset de imagens para testes |
| Do (Fazer) | <ul style="list-style-type: none">• Implementar algoritmo de enquadramento e detecção de bordas• Desenvolver módulo de cálculo de área por contornos• Criar sistema de análise cromática baseado no RYB• Implementar sistema de calibração com quadrado de referência |
| Check (Verificar) | <ul style="list-style-type: none">• Testar algoritmos individualmente com dataset de imagens• Medir precisão na detecção de bordas (sobreposição mínima 80%)• Avaliar acurácia no cálculo de área (erro percentual)• Analisar consistência da classificação de cores RYB• Validar sistema de calibração com quadrado de referência |
| Act (Agir) | <ul style="list-style-type: none">• Ajustar parâmetros do algoritmo de detecção de bordas• Otimizar algoritmo de classificação cromática• Documentar versão estável dos algoritmos |

Fonte: Elaborado pelo autor

3.2.1 PLAN (Planejar)

A primeira etapa do ciclo consiste em definir as metas e processos necessários para alcançar o resultado esperado, sendo imprescindível no desenvolvimento de software, pois estabelece o escopo, os requisitos e as tecnologias a serem utilizadas. No contexto da solução proposta, essa fase concentrou-se especialmente na definição dos requisitos funcionais do sistema, na investigação e seleção das tecnologias adequadas, no planejamento da arquitetura dos módulos e na obtenção das imagens que seriam utilizadas durante os testes.

Para identificar os requisitos necessários para o sistema, foi necessário estudar o processo manual de mensuração e análise de ferimentos para identificar quais funções deveriam ser implementadas, bem como a resposta a ser obtida desses métodos. Sendo assim, as principais funcionalidades mapeadas foram: obter a área do ferimento analisado, obter as cores do ferimento, cadastrar pacientes e associar a análise da ferida ao paciente ao qual ela pertence.

A seleção das tecnologias foi alinhada a definição dos requisitos, a escolha do python se deu pela facilidade da linguagem em operar o processamento de imagens junto a biblioteca OpenCV que tem uma extensa gama de funções lógicas já implementadas para análise de imagem com foco em obtenção de contornos e detecção de cores.

Com as tecnologias definidas, foi possível verificar os algoritmos disponíveis e elaborar a estrutura dos principais módulos do sistema, bem como mapear quais funções poderiam ser utilizadas na detecção de bordas e contornos, bem como a análise cromática para classificar usando o sistema RYB.

Para viabilizar os testes e validação do sistema, foi necessário definir o dataset de imagens que seria utilizado durante o desenvolvimento. As imagens de ferimentos foram obtidas através dos dados públicos da Escola de Enfermagem de Ribeirão Preto da Universidade de São Paulo¹ (CALIRI, 2020) e do dataset disponibilizado pela University of Wisconsin–Milwaukee e pela clínica Advancing the Zenith of Healthcare (AZH) Wound and Vascular Center², descrito em Wang et al. (2020).

¹ http://eerp.usp.br/feridas/cronicas/serie_fotografia.html

² https://github.com/uwm-bigdata/wound-segmentation/tree/master/data/wound_dataset

3.2.2 DO (Fazer)

A segunda fase consiste na execução prática do que foi estabelecido durante o planejamento. Esta fase visa implementar os processos, algoritmos e funcionalidades definidos na etapa anterior.

No desenvolvimento de software, a etapa DO é caracterizada pela codificação, buscando implementar com as tecnologias definidas, os requisitos estabelecidos. Para o sistema Bio-CV, esta fase concentrou-se na implementação dos algoritmos de processamento de imagem, desenvolvimento da interface gráfica e integração de todos os componentes em um sistema funcional.

A aplicação prática do desenvolvimento iterativo e incremental ocorreu em cada iteração, cada módulo funcional foi implementado, testado individualmente e refinado antes de avançar para o próximo componente. Por exemplo, o algoritmo de detecção de bordas foi desenvolvido em várias iterações, testando diferentes parâmetros do detector Canny até obter resultados precisos. Somente após validar esse incremento, passou-se ao desenvolvimento do módulo de cálculo de área. Essa estratégia garantiu que cada parte do sistema fosse validada progressivamente, reduzindo retrabalho e permitindo correções sem impactar módulos já estáveis.

Para implementar o módulo de processamento de imagem, traçamos um fluxo lógico para o algoritmo: enquadramento → bordas → máscara → extração → cores. Inicialmente a ferida é enquadrada, diminuindo a área de detecção, seguindo pela aplicação de algoritmos para a detecção das bordas do ferimento. Com as bordas detectadas, criamos uma máscara binária que delimita a de forma precisa o ferimento, e com isso, extraímos apenas o ferimento da imagem original, podendo em seguida detectar as cores presentes no mesmo, bem como obter a quantidade de *pixels* do ferimento.

Para calcular a área real do ferimento foi necessário obter uma referência de tamanho da realidade, utilizamos um quadrado de cor específica, e área conhecida para servir como padrão. Dessa forma conseguimos converter a quantidade de *pixels* do ferimento para unidades médicas reais.

O sistema de análise cromática foi desenvolvido no espaço de cores HSV, permitindo classificar cada *pixel* segundo o sistema RYB (Red-Yellow-Black) para identificar diferentes estágios de cicatrização.

3.2.3 CHECK (Verificar)

A terceira etapa do método baseia-se em validar se os resultados obtidos da etapa anterior (DO) estão em acordo ao que foi planejado na primeira etapa (PLAN). Dessa forma, essa fase envolve testar o sistema desenvolvido buscando avaliar quais pontos necessitam de melhorias ou ajustes, estes, se observados, deverão ser corrigidos na etapa posterior.

Para aplicar no desenvolvimento do Bio-CV, foi utilizado os datasets públicos de imagens de ferimentos da Universidade de São Paulo e do dataset da University of Wisconsin–Milwaukee (UWM) e AZH Wound and Vascular Center como base para validação do sistema, sendo utilizadas 50 imagens para as etapas de validação.

O processo de verificação foi estruturado de forma sistemática, testando individualmente cada módulo do sistema (detecção de bordas, cálculo de área e análise cromática) antes de avaliar o desempenho conjunto da solução. Esta metodologia permitiu identificar cenários específicos onde ajustes seriam necessários para otimizar o desempenho da solução.

A validação dos algoritmos principais do sistema envolveu testes específicos para cada módulo desenvolvido. Para a detecção de bordas, foi realizada uma comparação entre as bordas identificadas pelo algoritmo Canny e o mapeamento manual, considerando como correta a sobreposição de pelo menos 80% entre as detecções. A avaliação do cálculo de área baseou-se na comparação entre medições automáticas e manuais, calculando-se o erro percentual através da fórmula: $| \text{área_automática} - \text{área_manual} | / \text{área_manual} \times 100$, utilizando o mesmo quadrado azul de calibração em ambas as análises. Para a classificação cromática RYB, foi verificada a consistência entre a categorização automática e manual das cores presentes nos ferimentos.

3.2.4 ACT (Agir)

A quarta e última etapa do ciclo PDCA, consiste em fazer as alterações identificadas na etapa anterior, com objetivo de evitar que os problemas observados voltem a se repetir. Além de correções, essa fase também implica em aplicar melhorias na solução.

No desenvolvimento do Bio-CV, a aplicação da etapa ACT baseou-se diretamente nos resultados obtidos durante a fase de verificação, onde foram identificados pontos específicos que necessitavam de ajustes para melhorar o

sistema. As principais ações tomadas incluíram o refinamento dos parâmetros do algoritmo que atua na detecção de bordas, e otimizações no algoritmo de classificação cromática RYB para aumentar a consistência na identificação das cores dos ferimentos.

As ações implementadas nesta etapa fecham o primeiro ciclo PDCA do desenvolvimento do Bio-CV, resultando em algoritmo base eficiente e funcional que atendeu aos critérios estabelecidos em consenso ao que foi planejado.

3.3 Segundo Ciclo PDCA - Interface E Integração

O Quadro 02 apresenta a distribuição das atividades desenvolvidas no segundo ciclo PDCA, focado em desenvolver a interface do Bio-CV e integrá-la com o algoritmo base desenvolvido no ciclo anterior, a divisão em dois ciclos seguindo a metodologia foi imprescindível para a divisão clara das fases do projeto, garantindo a qualidade de cada etapa.

Quadro 02: Distribuição das atividades do Segundo Ciclo PDCA - Interface e Integração

| Etapa | Atividades Realizadas |
|-------------------|--|
| Plan (planejar) | <ul style="list-style-type: none">• Definir requisitos da interface gráfica• Especificar tecnologia para interface (Tkinter)• Projetar layout e fluxo de navegação• Definir critérios de usabilidade• Planejar integração com algoritmos desenvolvidos |
| Do (Fazer) | <ul style="list-style-type: none">• Desenvolver interface gráfica com Tkinter• Implementar funcionalidades de upload de imagem• Criar sistema de enquadramento interativo• Desenvolver painéis de visualização de resultados• Integrar interface com algoritmos de processamento |
| Check (Verificar) | <ul style="list-style-type: none">• Testar funcionamento da interface gráfica• Validar integração entre interface e algoritmos• Testar comportamento em situações de erro• Avaliar clareza na apresentação dos resultados |
| Act (Agir) | <ul style="list-style-type: none">• Melhorar apresentação dos resultados |

| | |
|--|---|
| | <ul style="list-style-type: none"> • Otimizar descritivos das operações e telas • Corrigir problemas de integração identificados • Documentar versão final do sistema completo |
|--|---|

Fonte: Elaborado pelo autor

3.3.1 PLAN (Planejar)

O planejamento do segundo ciclo concentrou-se em definir os requisitos e especificações para desenvolver uma interface gráfica funcional e integrar todos os componentes em um sistema unificado. Com os algoritmos de processamento já validados no primeiro ciclo, esta etapa focou em projetar como os usuários finais interagiriam com a solução, estabelecendo critérios claros de usabilidade e definindo a arquitetura de integração entre interface e algoritmos.

Para definir os requisitos da interface gráfica, foi necessário considerar o perfil dos usuários finais - profissionais de saúde que necessitam de uma ferramenta intuitiva e de fácil operação.

A especificação da tecnologia Tkinter se deu por sua simplicidade de implementação, compatibilidade nativa com Python e capacidade de criar interfaces funcionais sem complexidade desnecessária. O fluxo de navegação foi projetado de forma linear e intuitiva: selecionar paciente → upload da imagem → enquadramento do ferimento → processamento automático → visualização dos resultados, garantindo que cada etapa fosse clara e eficiente.

O planejamento da integração definiu como a interface se relacionaria com os algoritmos, estabelecendo um fluxo de dados eficiente onde a imagem carregada pelo usuário seria processada pelos algoritmos e os resultados apresentados de forma organizada e compreensível.

3.3.2 DO (Fazer)

A implementação da interface seguiu o planejamento estabelecido na seção anterior, a abordagem adotada priorizou a criação dos componentes visuais antes da integração com os algoritmos já validados, permitindo testes isolados de cada funcionalidade antes da implementação completa do sistema.

Assim como no primeiro ciclo, o desenvolvimento iterativo e incremental foi aplicado durante esta fase. Cada componente da interface foi construído em

iterações sucessivas: inicialmente desenvolveu-se a interface base do sistema, com o login, cadastro, registro de pacientes e ferimentos, em seguida iniciou-se o upload de imagens, que passou por várias iterações até garantir validação adequada. Em seguida, o enquadramento interativo foi implementado e refinado através de testes com diferentes tipos de seleção. Somente após validar cada incremento individualmente, procedeu-se à integração com os algoritmos do primeiro ciclo, garantindo estabilidade progressiva do sistema completo.

A implementação da interface gráfica utilizou os recursos do Tkinter para criar os painéis conforme estrutura projetada. O sistema de upload foi desenvolvido através de diálogos de seleção que permitiam carregar imagens nos formatos JPEG e PNG, com validação automática do tipo de arquivo.

O enquadramento interativo foi implementado permitindo ao usuário selecionar a região do ferimento através de cliques, criando um retângulo que delimita a área a ser processada. Os painéis de visualização de resultados foram desenvolvidos para apresentar simultaneamente a análise sobre a mensuração e cores.

A integração com os algoritmos de processamento foi implementada através de chamadas diretas às funções já validadas no primeiro ciclo, onde a região selecionada pelo usuário é enviada sequencialmente para os módulos de detecção de bordas, cálculo de área e análise cromática

3.3.3 CHECK (Verificar)

A validação do funcionamento da interface gráfica foi realizada através de testes sistemáticos de cada componente desenvolvido. Os testes incluíram verificação do carregamento correto de imagens, funcionamento adequado dos botões de controle e responsividade do sistema de enquadramento interativo.

A integração entre interface e algoritmos foi validada através da execução completa do fluxo de processamento, confirmando que os dados eram transmitidos corretamente entre os módulos e que os resultados eram apresentados adequadamente.

A avaliação da clareza na apresentação dos resultados foi realizada analisando a disposição visual das informações de área calculada, classificação cromática RYB e visualização das bordas detectadas. Os testes confirmaram que os resultados eram exibidos de forma organizada e compreensível, permitindo aos

usuários interpretar facilmente as informações geradas pelo sistema de análise automatizada.

3.3.4 ACT (Agir)

Com base nos resultados dos testes de validação, foram implementadas melhorias na apresentação dos resultados para tornar as informações mais claras e organizadas visualmente. Os descritivos das operações e telas foram otimizados, incluindo instruções mais diretas para o usuário e melhor identificação dos elementos da interface. Essas alterações tiveram como objetivo reduzir possíveis dúvidas durante o uso do sistema e tornar a experiência mais intuitiva

Os problemas de integração identificados durante os testes foram corrigidos, garantindo que a comunicação entre interface e algoritmos ocorresse de forma eficiente e sem falhas. Foram ajustados aspectos relacionados ao tempo de resposta do sistema e ao tratamento de exceções em situações de erro, resultando em maior estabilidade operacional

A documentação da versão final do sistema completo foi elaborada incluindo especificações técnicas, instruções de uso e registro das funcionalidades implementadas. As ações de correção implementadas nesta etapa finalizaram o segundo ciclo PDCA, resultando em um sistema *Bio-CV* integrado e funcional.

4. Solução

O *Bio-CV* é um sistema desktop desenvolvido em Python que integra técnicas de visão computacional para análise automatizada de ferimentos cutâneos, por meio de imagens fotográficas. A solução foi estruturada em dois módulos independentes, mas conectados entre si: o módulo da interface, responsável pela interação do usuário com o sistema, e o módulo de processamento de imagem, sendo esse o core da aplicação, responsável pela análise.

4.1 Requisitos do Sistema

4.1.1 Requisitos funcionais

Os requisitos funcionais definem as funcionalidades que o sistema deve oferecer para atender às necessidades dos usuários e garantir o adequado gerenciamento de pacientes e ferimentos. A seguir, são apresentados os principais requisitos funcionais do sistema:

- O sistema deve ser capaz de criar, atualizar e consultar um usuário.
- O sistema deve ser capaz de criar, atualizar e consultar um paciente.
- O sistema deve ser capaz de criar e excluir um registro de ferimento.
- O sistema deve ser capaz de analisar as imagens dos ferimentos associando-as a um determinado paciente.
- O sistema deve ser capaz de associar novas mensurações a um ferimento já existente.
- O sistema deve ser capaz de armazenar os dados obtidos no processo de análise das imagens dos ferimentos.

4.1.2 Requisitos não funcionais

Os requisitos não funcionais estão relacionados às necessidades técnicas para o funcionamento da solução. São critérios de qualidade e experiência do usuário (UX) que você define e tem que avaliar se foram atendidos ou não.

- O sistema deve ser desenvolvido utilizando a linguagem de programação **Python**.
- O sistema deve utilizar o sistema de gerenciamento de banco de dados **MySQL** para armazenamento dos dados.
- O sistema deve utilizar a biblioteca **OpenCV** para processamento e análise de imagens.
- O sistema deve utilizar a biblioteca **Scikit-learn** para implementação do algoritmo K-Means na análise cromática.
- O sistema deve utilizar a biblioteca **Tkinter** para desenvolvimento da interface gráfica.
- O sistema deve ser compatível com o sistema operacional **Windows**.
- O sistema deve garantir a confiabilidade dos dados dos pacientes e da anamnese armazenados.

- O sistema deve priorizar a usabilidade, permitindo que as interações sejam realizadas com a menor interferência possível da habilidade técnica do usuário.

4.2 Arquitetura do Sistema

O sistema *BIO-CV* adota uma arquitetura de aplicação desktop integrada, desenvolvida para proporcionar uma solução completa e autossuficiente para análise e acompanhamento de ferimentos cutâneos. A estrutura do sistema é composta por três camadas principais: camada de apresentação (interface gráfica), camada de processamento (análise de imagens e lógica de negócio) e camada de persistência (banco de dados MySQL). Esta organização permite a separação de responsabilidades, facilitando a manutenção e evolução do sistema.

4.2.1 Organização dos Módulos

O sistema é estruturado em um módulo desktop único que integra todas as funcionalidades necessárias. Este módulo é subdividido em componentes especializados:

- **Módulo de Autenticação:** Responsável pelo gerenciamento de usuários, realizando login, logout e controle de acesso às funcionalidades do sistema.
- **Módulo de Gerenciamento de Pacientes:** Gerencia o cadastro, atualização e consulta de informações dos pacientes, incluindo dados pessoais e histórico clínico.
- **Módulo de Análise de Imagens:** Componente central do sistema, responsável pelo processamento digital das imagens de ferimentos utilizando técnicas de visão computacional. Realiza operações de segmentação, mensuração de área e perímetro, e análise cromática.
- **Módulo de Visualização:** Apresenta os resultados das análises permitindo o acompanhamento da evolução do processo cicatricial ao longo do tempo.
- **Módulo de Persistência:** Gerencia todas as operações de comunicação com o banco de dados MySQL, incluindo armazenamento e recuperação de dados de usuários, pacientes, ferimentos e mensurações.

4.2.2 Fluxo de Dados

O fluxo de dados no sistema *BIO-CV* segue uma sequência lógica que garante a integridade e rastreabilidade das informações:

1. **Entrada de Dados:** O usuário autenticado acessa o sistema através da interface gráfica e seleciona ou cadastra um paciente. Em seguida, submete uma imagem do ferimento a ser analisada.
2. **Processamento:** A imagem é encaminhada ao módulo de análise, onde são aplicados algoritmos de visão computacional para segmentação do ferimento, cálculo de área e perímetro, e extração de características cromáticas. Os resultados são processados e formatados para apresentação.
3. **Armazenamento:** Os dados obtidos na análise (área, perímetro, cores predominantes, data da mensuração) são associados ao registro do ferimento correspondente e armazenados no banco de dados MySQL, mantendo o histórico completo de evolução.
4. **Visualização:** Os resultados da análise são apresentados ao usuário através da interface, permitindo comparações entre diferentes mensurações e avaliação da evolução do processo cicatricial.
5. **Consulta e Acompanhamento:** O sistema permite consultar o histórico completo de mensurações de um ferimento, facilitando a tomada de decisões clínicas baseadas na evolução documentada ao longo do tratamento.

4.3 Módulo de Processamento de Imagem

O módulo de processamento de imagem constitui o componente central do sistema *BIO-CV*, responsável pela análise automatizada de ferimentos cutâneos através de técnicas de visão computacional. Este módulo é subdividido em três componentes principais que trabalham de forma integrada.

4.3.1 Algoritmo de Detecção de Bordas

A detecção precisa das bordas do ferimento é realizada através da implementação do algoritmo Active Contour (Snake), uma técnica avançada de

segmentação que permite a identificação de contornos irregulares com alta precisão. O processo de detecção segue as seguintes etapas:

Pré-processamento da imagem:

- Conversão da imagem para escala de cinza, reduzindo a complexidade computacional e facilitando o processamento subsequente.
- Aplicação de suavização Gaussiana para redução de ruído, preparando a imagem para a detecção de bordas.
- Aplicação do operador Sobel para detecção de gradientes de intensidade nas direções horizontal e vertical, destacando as bordas presentes na imagem.

Inicialização do Active Contour:

- Definição de um contorno inicial em forma de elipse, posicionado no centro da região de interesse (ROI) selecionada pelo usuário.
- Os parâmetros da elipse inicial são calculados com base nas dimensões da ROI, garantindo uma aproximação adequada do ferimento.

Segmentação com Snake Algorithm:

- O algoritmo Active Contour é aplicado utilizando os parâmetros otimizados: α (0.015) para controle da elasticidade do contorno, β (10) para controle da rigidez, e γ (0.001) para taxa de convergência.
- O contorno evolui iterativamente, ajustando-se às bordas reais do ferimento detectadas pelos gradientes de intensidade.
- O resultado é um contorno preciso que delimita exatamente a área do ferimento, mesmo em casos de formas irregulares.

Criação da máscara de segmentação:

- A partir do contorno final obtido pelo Snake, é gerada uma máscara binária que isola completamente o ferimento do restante da imagem.
- Esta máscara é utilizada para extrair apenas a região do ferimento, permitindo análises subsequentes focadas exclusivamente na área afetada.

4.3.2 Cálculo de Área

O cálculo preciso da área do ferimento é fundamental para o acompanhamento da evolução do processo cicatricial. O sistema implementa um método robusto que fornece medições tanto em pixels quanto em unidades reais (centímetros quadrados):

Calibração através de adesivo de referência:

- O sistema detecta automaticamente um adesivo azul de dimensões conhecidas (1cm²) presente na imagem, como demonstrado na figura 19.

Figura 19: Detecção do adesivo de referência pelo *BIO-CV*



Fonte: Adaptado de Salviano et al. (2025)

- A detecção é realizada através de segmentação no espaço de cores HSV, isolando especificamente a faixa cromática correspondente ao azul do adesivo.
- A área em pixels do adesivo é calculada, estabelecendo um fator de conversão entre pixels² e cm².

Cálculos de área:

- **Área em pixels:** Calculada diretamente a partir do contorno obtido pelo Active Contour, utilizando a função de cálculo de área de contorno do OpenCV.

- **Área real:** Convertida de pixels para centímetros quadrados aplicando o fator de conversão obtido na calibração com o adesivo de referência.
- **Perímetro:** Calculado tanto em pixels quanto em centímetros, fornecendo informação adicional sobre o formato e extensão do ferimento.

Métricas complementares:

- **Circularidade:** Calculada pela fórmula $(4\pi \times \text{área}) / (\text{perímetro}^2)$, fornecendo um índice que varia de 0 a 1, onde 1 indica um círculo perfeito. Esta métrica auxilia na caracterização da regularidade do ferimento.
- **Solidez:** Razão entre a área do ferimento e a área do seu envoltório convexo, indicando o quão "preenchida" é a forma do ferimento.
- **Dimensões do bounding box:** Largura e altura do menor retângulo que envolve completamente o ferimento, úteis para estimativas rápidas de tamanho.

4.3.3 Análise Cromática

A análise cromática fornece informações essenciais sobre o estado do ferimento, uma vez que diferentes cores estão associadas a diferentes estágios do processo cicatricial e possíveis complicações. O sistema implementa um pipeline completo de análise de cores:

Conversão de espaços de cores:

- **Espaço HSV (Hue, Saturation, Value):** Separa a informação de cor (matiz) da intensidade luminosa, facilitando a identificação de características cromáticas independentemente da iluminação. Os canais H, S e V são extraídos e analisados individualmente.
- **Espaço Lab:** Representa cores de forma perceptualmente uniforme, com o canal L representando luminância, e os canais A e B representando as componentes verde-vermelho e azul-amarelo, respectivamente. Este espaço é especialmente útil para análises clínicas de cor.

Clustering de cores com K-Means:

- Aplicação do algoritmo K-Means para identificar as cores dominantes presentes no fermento.
- O algoritmo agrupa pixels com cores similares em clusters (padrão: 5 clusters), identificando automaticamente as tonalidades predominantes.
- Remoção automática de pixels correspondentes ao fundo branco, garantindo que apenas as cores do fermento sejam analisadas.

Quantificação e visualização:

- **Cálculo de percentuais:** Para cada cor identificada, é calculado o percentual de área que ela representa no fermento total.
- **Códigos hexadecimais:** Cada cor dominante é representada em formato hexadecimal RGB, facilitando a documentação e comunicação dos resultados.
- **Paleta de cores:** Geração de uma visualização gráfica mostrando as cores detectadas com seus respectivos percentuais.
- **Gráfico de distribuição:** Criação de um gráfico de pizza ilustrando a proporção de cada cor no fermento.
- **Mapa de cores:** Geração de uma imagem segmentada mostrando espacialmente onde cada cor predominante aparece no fermento.

4.4 Interface Gráfica

A interface gráfica do sistema *BIO-CV* foi desenvolvida utilizando a biblioteca Tkinter. O design da interface prioriza a clareza na apresentação das informações e a facilidade de navegação, evitando complexidades e facilitando o entendimento dos dados exibidos.

Anexadas abaixo (Figura 20, Figura 21, e Figura 22) estão as três principais telas do sistema proposto, o design da interface do sistema na íntegra pode ser encontrado no Figma³:

Figura 20: Tela de cadastro de fermento

³ <https://www.figma.com/design/i3Cn4Mt2NOWNxf4xOECinO/BIO-CV?node-id=0-1&t=9SMonBfYbTUe8ppf-1>

Cadastro de Ferimento - Teste - BIO-CV

[← Voltar](#)

Cadastrar Novo Ferimento

Paciente: Teste

Descrição do ferimento:

Descreva detalhadamente o ferimento (tipo, características, causa, etc.)

Data do ferimento: 24/11/2025

Localização no corpo: Ex: Braço direito, perna esquerda, tórax...

Cadastrar Ferimento

Fonte: Autores

Figura 21: Tela de envio de imagens

Análise de Ferimento - Teste - BIO-CV

[← Voltar](#)

Sistema de Análise de Ferimentos por Imagem

Selecione a imagem

Arraste a imagem aqui ou clique para selecionar

Analisar Ferimento

Este sistema auxilia na mensuração automática da área e das cores dos ferimentos a partir de imagens capturadas.

Funcionalidades Principais:

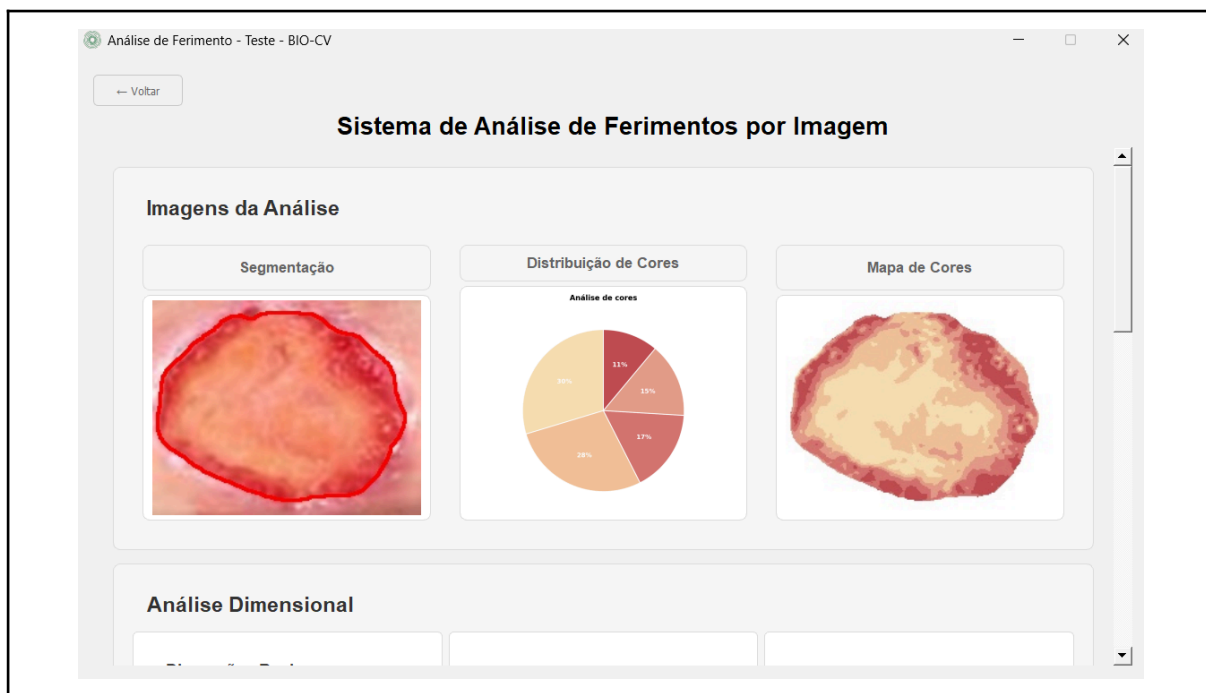
- **Análise de Área:** O sistema utiliza tecnologia de visão computacional para identificar a área do ferimento, proporcionando medições para acompanhamento da cicatrização ao longo do tempo.
- **Deteção de Cores:** O sistema identifica as diferentes cores presentes no ferimento, permitindo uma avaliação detalhada da condição da pele e dos tecidos afetados.

Como Funciona:

1. **Upload da Imagem:** Envie uma foto clara do ferimento.
2. **Análise Automática:** O sistema processará a imagem e exibirá os resultados em poucos segundos, incluindo a área total do ferimento e a distribuição de cores.
3. **Visualização de Resultados:** Visualize os resultados diretamente na tela.

Fonte: Autores

Figura 22: Tela análise de resultados



Fonte: Autores

4.5 Integração e Funcionamento

A integração entre os módulos do sistema BIO-CV ocorre de forma coordenada e automatizada, garantindo a fluidez do processo de análise e a consistência dos resultados. O sistema foi arquitetado para que cada módulo desempenhe sua função específica de maneira independente, mas integrada através de interfaces bem definidas e simples que facilitam a comunicação e o compartilhamento de dados.

O fluxo operacional inicia-se com a autenticação do usuário no módulo de login, que valida as credenciais e estabelece a sessão de trabalho. Uma vez autenticado, o usuário acessa o módulo de gerenciamento de pacientes, onde pode selecionar um paciente existente ou cadastrar um novo registro. Esta integração com o banco de dados MySQL garante que todas as informações sejam persistidas de forma segura e organizada.

Ao submeter uma nova imagem para análise, o sistema aciona automaticamente o módulo de processamento de imagens, que executa sequencialmente os algoritmos de detecção de bordas, cálculo de área e análise cromática.

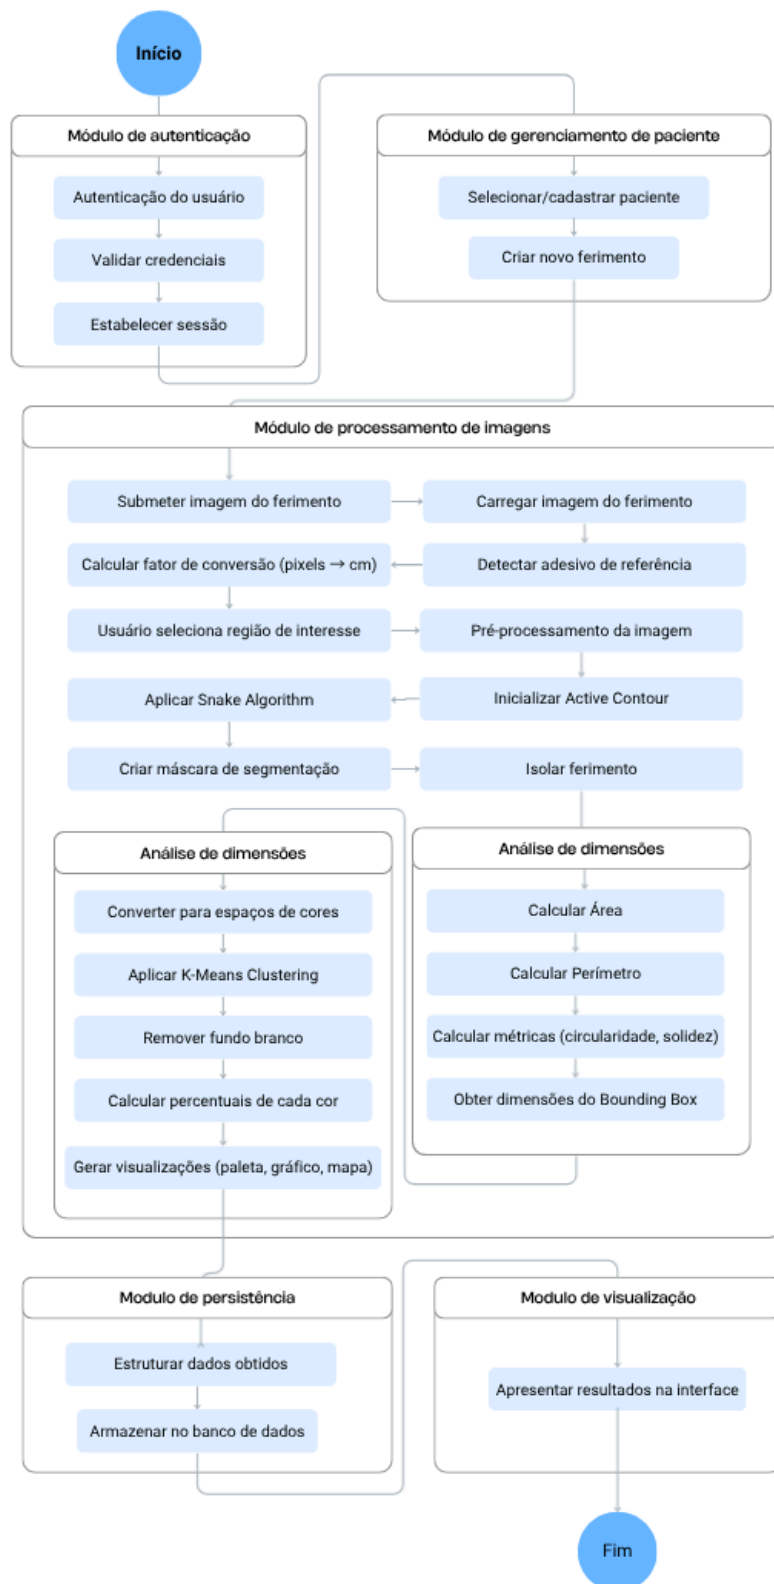
Os resultados obtidos pelo módulo de processamento são então estruturados e enviados ao módulo de persistência, que realiza a inserção dos dados no banco

de dados, associando-os ao registro do paciente e ao ferimento específico, juntamente com o timestamp da análise. Esta integração permite que o histórico completo de mensurações fique disponível para consultas futuras e análises comparativas.

Finalmente, o módulo de visualização recupera os dados armazenados e os apresenta de forma organizada e de fácil entendimento na interface gráfica, utilizando componentes visuais como tabelas, gráficos e imagens processadas. Esta apresentação integrada permite que o usuário tenha uma visão completa e objetiva do estado atual do ferimento e de sua evolução ao longo do tratamento.

A arquitetura integrada do sistema garante que todo o fluxo, iniciando da captura da imagem até a exibição dos dados obtidos pela análise, ocorra de forma fluida e transparente, minimizando a necessidade de intervenção manual.

Figura 23: Fluxograma do funcionamento do BIO-CV



Fonte: Autores

5. Resultados e discussões

5.1 Considerações Iniciais sobre a Validação

O presente trabalho propôs-se a investigar a viabilidade do desenvolvimento de um sistema capaz de analisar ferimentos cutâneos de forma automatizada mediante registros fotográficos. Para responder à questão de pesquisa levantada: *"É possível desenvolver um sistema que analisa ferimentos cutâneos de forma automatizada por meio de imagens fotográficas?"*, foi desenvolvido o *Bio-CV*, um sistema desktop que integra técnicas de visão computacional para mensuração de área e identificação de cores em ferimentos.

A validação realizada nesta etapa da pesquisa concentrou-se em demonstrar a viabilidade técnica e funcional da solução proposta. Para isso, foram conduzidos testes com 50 imagens do datasets públicos previamente citados, avaliando a capacidade do sistema em executar as funções para as quais foi projetado: segmentar ferimentos em imagens fotográficas, calcular áreas relativas através de calibração com adesivo de referência, e quantificar a distribuição cromática segundo padrões clinicamente relevantes.

É importante destacar que esta primeira versão do *Bio-CV* foi validada através de análise visual qualitativa, com foco na funcionalidade dos algoritmos implementados e na consistência dos resultados gerados. A abordagem adotada consistiu em verificar se o sistema é capaz de produzir segmentações visualmente coerentes, medições reprodutíveis e análises cromáticas que correspondam à aparência visual dos ferimentos processados.

Dessa forma, os resultados apresentados nas seções seguintes concentram-se em demonstrar que:

1. O sistema é funcionalmente operacional, executando todas as etapas propostas de forma automatizada;
2. Os algoritmos implementados são capazes de processar imagens reais de ferimentos com diferentes características;

3. Os resultados gerados são visualmente coerentes e internamente consistentes, apresentando potencial para aplicação clínica após validação quantitativa;

4. A abordagem baseada em visão computacional é tecnicamente viável para a análise automatizada de ferimentos cutâneos.

A próxima seção apresenta a validação funcional de cada algoritmo de processamento de imagem do sistema, seguida pela análise de casos específicos que ilustram o comportamento do sistema *Bio-CV* em diferentes cenários clínicos.

5.2 Validação Funcional dos Algoritmos de Processamento de imagem

O Módulo de Análise de Imagens, descrito na seção 4.3, constitui o núcleo do sistema *Bio-CV* e implementa três algoritmos principais que operam de forma integrada: (1) detecção de bordas através do algoritmo Active Contour, (2) cálculo de área e métricas por meio de calibração com adesivo de referência, e (3) análise cromática utilizando clustering K-Means para identificação de cores dominantes.




Esta seção apresenta a validação funcional de cada um desses algoritmos, demonstrando sua capacidade operacional e discutindo os resultados obtidos durante os testes realizados com os datasets públicos utilizados para o desenvolvimento do sistema, já citados anteriormente neste documento, foram utilizadas 50 imagens para a validação.

5.2.1 Algoritmo de Detecção de Bordas com Active Contour

O algoritmo de detecção de bordas, implementado através do método Active Contour (Snake), constitui a primeira etapa do processamento e é fundamental para todo o sistema, pois a precisão da segmentação impacta diretamente todos os passos posteriores. O algoritmo foi testado com as imagens dos datasets de teste, contemplando ferimentos com diferentes características morfológicas: bordas bem definidas, contornos irregulares, presença de exsudato e variações de tonalidade.


A figura 24 apresenta três casos do processo de detecção de borda com ferimentos com diferentes características.

Figura 24: Resultados da detecção por Active Contour em diferentes tipos de ferimentos

| |
|--|
| (a) Caso A |
|  |
| (b) Caso B |
|  |
| (c) Caso C |
|  |
| (d) Caso D |



(e) Caso E



Fonte: Autores

O Caso A (Figura 24a) apresenta um ferimento localizado na sola do pé, caracterizado por bordas relativamente bem definidas e contraste adequado entre a lesão e a pele circundante. Observa-se que o ferimento possui formato arredondado com poucas irregularidades. O algoritmo Active Contour detectou satisfatoriamente o contorno final (linha vermelha) adaptando-se adequadamente aos limites do ferimento. A segmentação resultante demonstrou boa correspondência visual com os limites perceptíveis da lesão, delimitando a extensão do ferimento de forma satisfatória. Nota-se que o contorno inicial em elipse (linha verde) estava próximo às bordas reais, facilitando a convergência do algoritmo.

O Caso B (Figura 24b) apresenta maior complexidade devido à morfologia irregular do ferimento, que possui formato alongado com múltiplas irregularidades e variações significativas de largura ao longo do seu comprimento. O ferimento, localizado em região de membro inferior, exhibe bordas serrilhadas e presença de tecido com tonalidade heterogênea, incluindo áreas mais escuras que sugerem necrose ou tecido desvitalizado. Apesar da complexidade morfológica, o contorno evoluiu de forma satisfatória, ajustando-se às diversas irregularidades da lesão.

O Caso C (Figura 24c) representa uma situação intermediária, com um ferimento apresentando formato ovalado com leve assimetria. A lesão possui bordas parcialmente definidas, com algumas regiões apresentando transição mais gradual entre o tecido lesionado e a pele perilesional. Observa-se também a presença de tonalidades variadas dentro do ferimento, incluindo áreas avermelhadas e regiões com coloração amarelada nas bordas, possivelmente indicando exsudato. O contorno final (linha vermelha) acompanhou adequadamente as bordas do ferimento, embora nas regiões de transição mais gradual a delimitação exata seja naturalmente mais desafiadora. O algoritmo conseguiu capturar satisfatoriamente a forma geral da lesão, incluindo as pequenas irregularidades presentes no contorno.

O Caso D (Figura 24d) apresenta um ferimento de formato alongado localizado em membro inferior, com características de lesão linear. A lesão exhibe bordas bem definidas ao longo de sua extensão, com coloração avermelhada intensa e presença de tecido de granulação, exceto na extremidade superior onde se observa textura e coloração diferentes, com aspecto mais claro que o resto do ferimento. O contorno inicial em formato elíptico (linha verde) foi posicionado acompanhando a orientação linear do ferimento. O algoritmo Active Contour evoluiu satisfatoriamente nas regiões de coloração homogênea, com o contorno final (linha vermelha) ajustando-se adequadamente às bordas laterais da lesão ao longo da maior parte de sua extensão. Entretanto, a extremidade superior do ferimento, que apresenta características visuais distintas do restante da lesão, não foi completamente capturada pela segmentação.

O Caso E (Figura 24e) apresenta um ferimento com formato bem definido e bordas predominantemente regulares. O contorno inicial (linha verde) foi posicionado abrangendo a região central da lesão. O algoritmo Active Contour evoluiu satisfatoriamente, com o contorno final (linha vermelha) acompanhando as bordas da lesão ao longo da maior parte de sua extensão. Entretanto, observa-se que na

região superior do ferimento existe uma reentrância que não foi capturada pela segmentação, com o contorno passando de forma reta sobre essa concavidade ao invés de acompanhar a entrada existente. A segmentação resultante delimitou de forma adequada a maior parte do ferimento, demonstrando boa correspondência visual com os limites da lesão, embora essa reentrância específica represente uma limitação pontual na detecção do contorno completo.

Com base nos testes realizados, o algoritmo Active Contour demonstrou capacidade de processar adequadamente ferimentos com diferentes características morfológicas. O desempenho foi particularmente satisfatório em casos como o Caso A, onde bordas bem definidas e contraste adequado facilitaram a convergência do algoritmo.

Em situações de maior complexidade, como ferimentos alongados com múltiplas irregularidades (Caso B e Caso D), o algoritmo manteve capacidade de adaptação, ajustando-se às variações de forma ao longo da lesão. Casos intermediários, com bordas parcialmente definidas e variações cromáticas (Caso C), foram processados satisfatoriamente, embora apresentem maior desafio em regiões de transição gradual.

Um aspecto importante observado foi a robustez do algoritmo em relação a contornos não-convencionais. Diferentemente de métodos baseados em formas geométricas pré definidas, o Active Contour demonstrou capacidade de adaptar-se a morfologias complexas, incluindo lesões com reentrâncias e variações significativas de largura, características frequentes em feridas.

Os casos que apresentaram maior dificuldade de processamento compartilhavam características específicas:

- **Qualidade de imagem:** Iluminação irregular, presença de sombras ou reflexos dificultaram a identificação de gradientes de intensidade necessários para guiar a convergência do contorno.
- **Bordas difusas:** Transições graduais entre tecido lesionado e pele saudável representaram o maior desafio, uma vez que não há gradiente bem definido para orientar o algoritmo, como no Caso D.
- **Reentrâncias profundas:** Concavidades no contorno do ferimento, como a observada na região superior do Caso E, e na região lateral do Caso B,

tendem a ser mais difíceis de detectar, podendo resultar em contornos mais retilíneos nessas áreas específicas.

- **Dependência do contorno inicial:** A qualidade da segmentação está relacionada à adequação da região de interesse selecionada e ao posicionamento inicial do contorno.
- **Coloração similar:** Ferimentos com tonalidade muito próxima à da pele circundante apresentaram menor contraste, dificultando a detecção automática de bordas.

Apesar dessas limitações, o algoritmo demonstrou-se funcionalmente adequado para a proposta do sistema, sendo capaz de segmentar automaticamente ferimentos com resultados visualmente coerentes em diferentes cenários clínicos.

5.2.2 Algoritmo de Cálculo de área

O algoritmo de cálculo de área é responsável por converter a segmentação obtida em medidas quantitativas clinicamente relevantes. O sistema implementa uma abordagem baseada em calibração através de adesivo de referência, permitindo a conversão de medidas em pixels para unidades reais (centímetros quadrados), possibilitando assim a obtenção de valores mensuráveis que podem ser utilizados para acompanhamento longitudinal da evolução do ferimento.

A calibração é realizada através da detecção automática de um adesivo azul de dimensões conhecidas (1 cm²) posicionado próximo ao ferimento no momento da captura fotográfica. Este processo é fundamental para estabelecer a correspondência entre pixels da imagem e unidades de medida reais. A Figura 25 ilustra o processo de detecção do adesivo de referência.

Figura 25: Detecção do adesivo de referência



Fonte: Autores

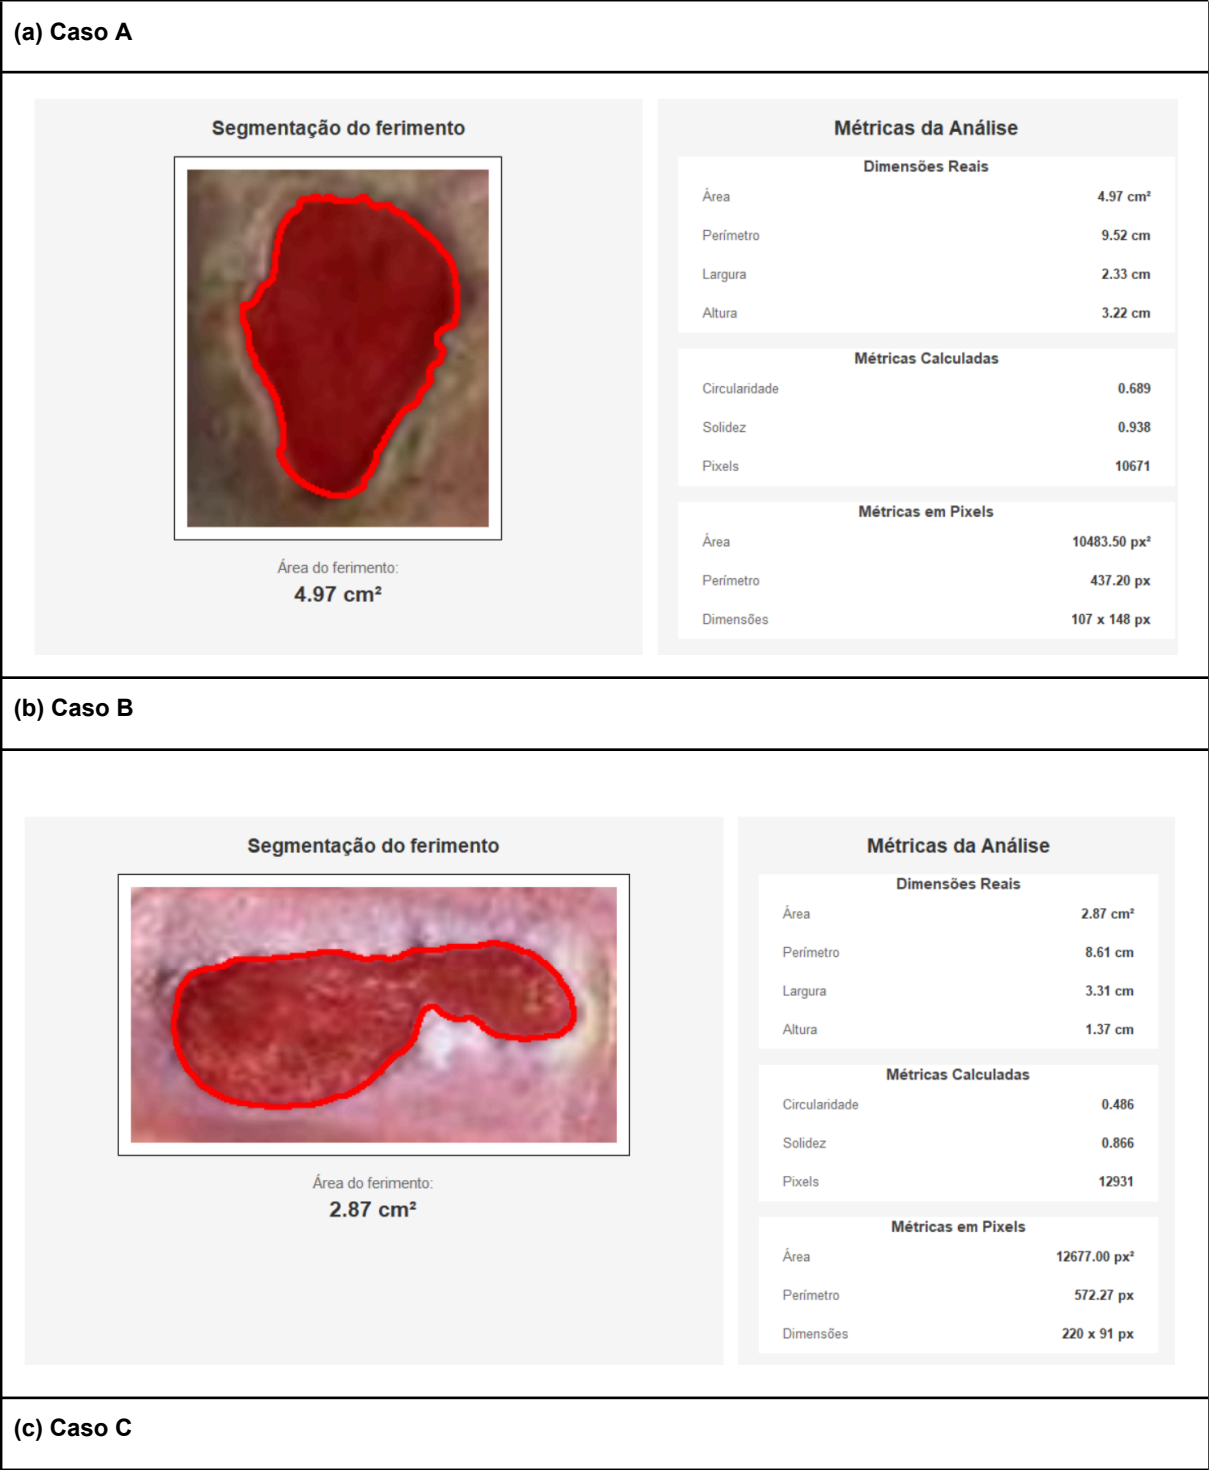
O processo de detecção utiliza segmentação no espaço de cores HSV (Hue, Saturation, Value), isolando especificamente a faixa cromática correspondente ao azul do adesivo. Os parâmetros de segmentação utilizados foram: Matriz entre 100° e 130° , Saturação entre 50 e 255, e Valor entre 50 e 255. Esta faixa foi determinada empiricamente para capturar o azul característico do adesivo enquanto exclui outros elementos azulados que possam estar presentes na cena.

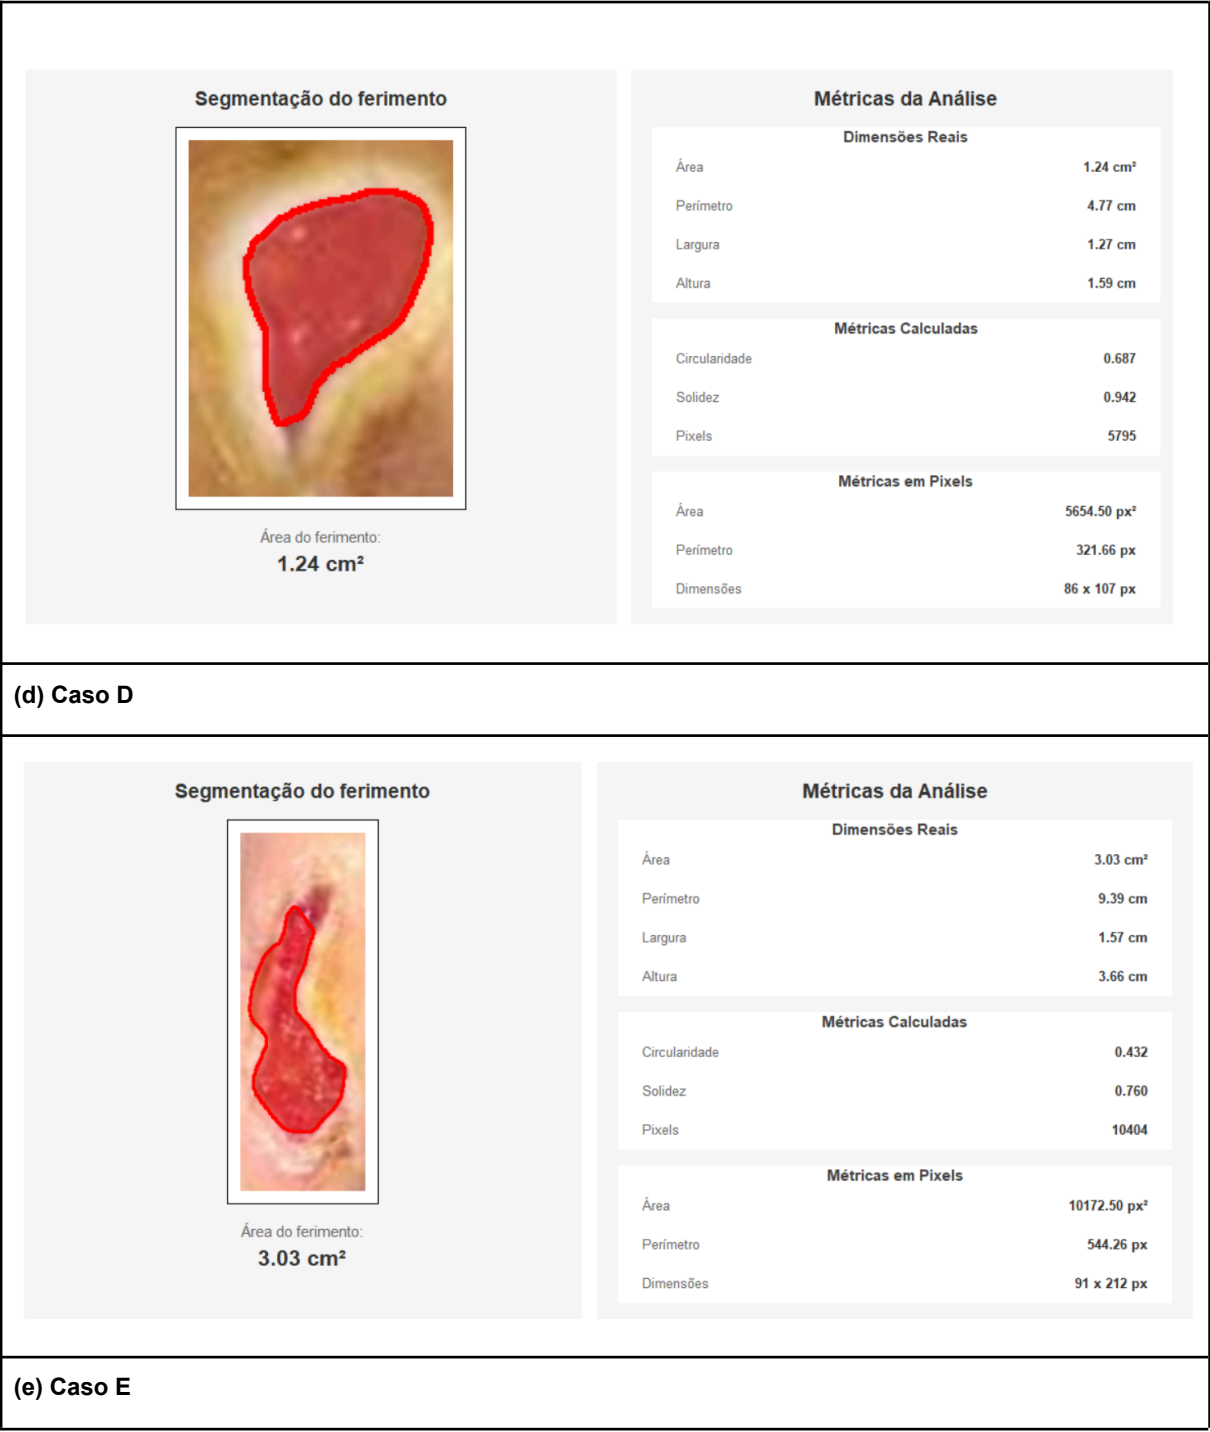
Após a segmentação, operações morfológicas de fechamento e abertura são aplicadas para eliminar ruídos e refinar a detecção. O maior contorno identificado na máscara resultante é considerado como o adesivo de referência, e sua área em pixels é calculada automaticamente. Uma vez detectado o adesivo, é calculada sua área em pixels, estabelece-se o fator de conversão dividindo a área em pixels pela área real conhecida (1 cm^2). Este fator é então utilizado para converter todas as medidas subsequentes de pixels para centímetros quadrados (área) ou centímetros lineares (perímetro, dimensões).

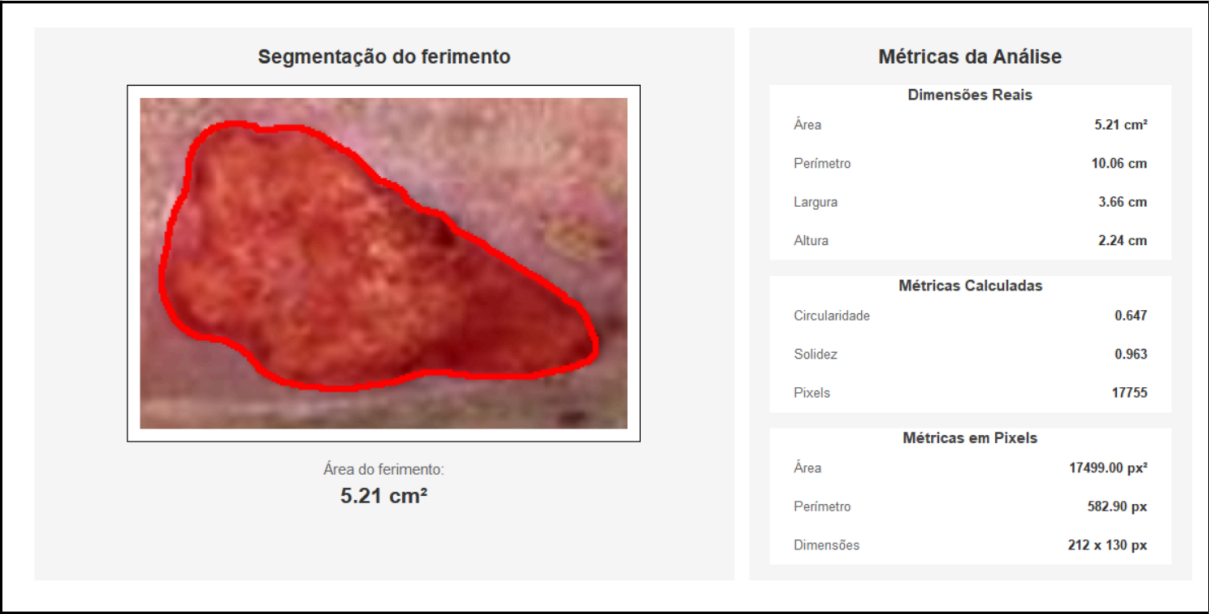
Uma vez estabelecido o fator de conversão através do adesivo de referência, o algoritmo calcula automaticamente um conjunto de métricas para caracterizar quantitativamente o ferimento. A Figura 26 apresenta exemplos visuais da aplicação

das métricas calculadas nos mesmos casos utilizados como exemplo no tópico anterior.

Figura 26: Visualização das métricas calculadas







Fonte: Autores

A tabela 1 resume os valores quantitativos das métricas calculadas para os três casos representativos apresentados anteriormente

Tabela 1: Métricas calculadas pelo algoritmo para os casos representativos

| Métrica | Caso A | Caso B | Caso C | Caso D | Caso E | Unidade |
|------------------------|----------|----------|---------|----------|----------|-----------------|
| Área (pixels) | 10419.00 | 12677.00 | 5679.50 | 10172.59 | 17499.00 | px ² |
| Área (calibrada) | 4.97 | 2.87 | 1.24 | 3.03 | 5.21 | cm ² |
| Perímetro (calibrado) | 9.52 | 8.61 | 4.77 | 9.39 | 10.06 | cm |
| Circularidade | 0.689 | 0.486 | 0.687 | 0.432 | 0.647 | 0-1 |
| Solidez | 0.938 | 0.866 | 0.942 | 0.760 | 0.963 | 0-1 |
| Largura (bounding box) | 2.33 | 3.31 | 1.27 | 1.57 | 3.66 | cm |
| Altura (bounding box) | 3.22 | 1.37 | 1.59 | 3.66 | 2.24 | cm |

Fonte: Autores

A área calibrada representa a medida fundamental do ferimento, expressa em centímetros quadrados após conversão através do fator de calibração. Esta métrica é essencial para o acompanhamento da evolução do ferimento ao longo do tempo, permitindo quantificar objetivamente a redução ou expansão da lesão. Observa-se

na tabela 1 que o Caso E apresenta a maior área (5.21 cm²), seguido pelo Caso D (3.03 cm²), Caso A (4.97 cm²), Caso B (2.87 cm²) e Caso C (1.24 cm²), refletindo as diferenças visíveis de tamanho entre as lesões.

O perímetro calibrado fornece informação complementar sobre a extensão das bordas do ferimento, sendo particularmente relevante para ferimentos alongados ou com contornos irregulares. O Caso E apresenta o maior perímetro (10.06 cm), seguido pelo Caso D (9.39 cm), esse, com sua morfologia alongada e linear, apresenta perímetro proporcionalmente maior em relação à sua área, enquanto os Casos A, C e E, com formas mais compactas, apresentam relação área/perímetro mais equilibrada.

A circularidade, calculada pela fórmula $(4\pi \times \text{área}) / (\text{perímetro}^2)$, fornece um índice que varia de 0 a 1, onde valores próximos a 1 indicam ferimentos com formato próximo ao circular, enquanto valores menores indicam formas mais irregulares ou alongadas. Observa-se que o Caso D apresenta a menor circularidade (0.432) devido à sua morfologia linear e alongada, semelhante ao Caso B que possui circularidade 0.486, enquanto os Casos A, C e E, com formas mais arredondadas, apresentam valores mais próximos de 1. Esta métrica pode ser útil para caracterização e classificação de diferentes tipos de lesões.

A solidez, definida como a razão entre a área do ferimento e a área do seu envoltório convexo, indica o grau de "preenchimento" da forma. Valores próximos a 1 representam ferimentos com contornos convexos e regulares, enquanto valores menores indicam presença de reentrâncias ou concavidades significativas. O Caso D apresenta solidez menor, seguido novamente pelo caso B, refletindo as múltiplas irregularidades observadas em seu contorno, enquanto os Casos A e C apresentam valores mais altos, indicando formas mais convexas. Esta métrica pode auxiliar na identificação de ferimentos com bordas serrilhadas ou áreas de retração.

No ferimento retratado na figura 27, podemos observar a variação da circularidade e solidez, de acordo com as definições atribuídas a eles nos parágrafos anteriores. Dessa forma, sendo o ferimento em questão mais circular e de bordas bem definidas, durante a análise ambos os valores se aproximam mais de 1, sendo respectivamente 0.867 e 0.986.

Figura 27: Detecção do adesivo de referência



Fonte: Autores

As dimensões do bounding box (menor retângulo que envolve completamente o ferimento) fornecem estimativas rápidas de largura e altura máximas da lesão, úteis para a documentação e comunicação entre profissionais de saúde.

O algoritmo de cálculo de área demonstrou-se funcionalmente operacional, fornecendo medições consistentes e um conjunto abrangente de métricas quantitativas. A abordagem baseada em calibração por adesivo de referência mostrou-se prática e implementável, não requerendo equipamentos especializados além da câmera fotográfica.

Os testes realizados demonstraram que o algoritmo produz valores numéricos consistentes quando aplicado às mesmas condições de entrada, indicando reprodutibilidade adequada do processamento. A automação do cálculo de todas as métricas após a segmentação elimina a necessidade de intervenção manual, tornando o processo mais eficiente e reduzindo a possibilidade de erros humanos na medição ou no registro dos dados.

O conjunto de métricas fornecidas (área, perímetro, circularidade, solidez, dimensões) oferece caracterização multidimensional do ferimento, permitindo não apenas quantificar seu tamanho, mas também descrever objetivamente sua forma e complexidade morfológica. Estas informações podem ser utilizadas para acompanhamento da evolução de ferimentos, comparações entre diferentes lesões,

documentação objetiva do processo cicatricial, e também auxiliar na classificação da ferida.

É importante ressaltar que, embora o algoritmo forneça valores numéricos consistentes e reprodutíveis baseados na calibração com o adesivo de referência, a presente validação concentrou-se em demonstrar a viabilidade técnica e funcional da abordagem proposta.

A acurácia absoluta dessas medidas, ou seja, o quão próximas as medições automatizadas estão das dimensões reais dos ferimentos, requer estudos comparativos controlados com métodos de referência estabelecidos e aprovação do conselho de ética, que poderão ser conduzidos em etapas futuras da pesquisa.

Algumas considerações práticas foram identificadas:

- Dependência do adesivo: O sistema requer a presença do adesivo de referência na imagem para conversão de medidas reais. Imagens sem o adesivo podem fornecer apenas medidas relativas em pixels.
- Ângulo de captura: A precisão da calibração assume que o adesivo e o ferimento estão aproximadamente no mesmo plano. Capturas em ângulos oblíquos ou em superfícies curvas do corpo podem introduzir distorções perspectivas que não são corrigidas pelo método atual.
- Qualidade da segmentação: A acurácia de todas as métricas depende fundamentalmente da qualidade da segmentação obtida na etapa anterior. Segmentações imprecisas resultarão em medições imprecisas.
- Iluminação do adesivo: Condições de iluminação que alterem significativamente a aparência cromática do adesivo podem dificultar ou impedir sua detecção automática.

Apesar dessas considerações, o algoritmo demonstrou viabilidade técnica para a proposta de análise automatizada de ferimentos cutâneos. A abordagem é compatível com práticas clínicas existentes e pode ser facilmente integrada a protocolos de acompanhamento de pacientes com feridas.

5.2.3 Algoritmo de Análise Cromática

O algoritmo de análise cromática é responsável por identificar e quantificar as cores presentes no ferimento, fornecendo informações essenciais sobre o estado da lesão. Diferentes cores estão associadas a diferentes estágios do processo

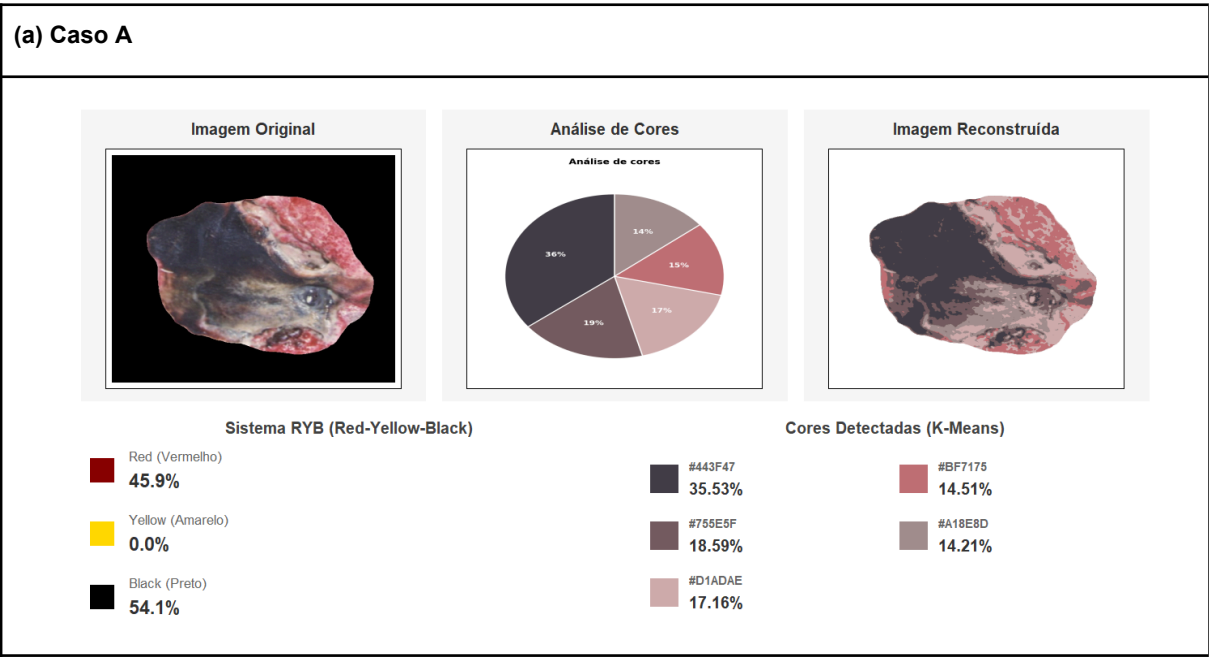
cicatricial e possíveis complicações, tornando a análise cromática um componente fundamental para avaliação clínica objetiva de ferimentos cutâneos.

O processamento cromático inicia-se após a segmentação do ferimento, utilizando a máscara binária obtida pelo algoritmo Active Contour para isolar exclusivamente os pixels pertencentes à lesão. O sistema implementa análise em múltiplos espaços de cores (HSV e Lab) para capturar diferentes aspectos da informação cromática, conforme descrito na seção de Fundamentação Teórica (seção 2.2.6).


A identificação das cores dominantes é realizada através do algoritmo de clustering K-Means, que agrupa pixels com características cromáticas similares. O algoritmo particiona o conjunto de pixels do ferimento em K grupos (clusters), onde cada grupo é representado por seu centroide, correspondente à cor média daquele grupo. Para os testes realizados, foram utilizados K=5 clusters, valor que demonstrou equilíbrio adequado entre detalhamento cromático e simplicidade de interpretação.

A Figura 28 apresenta os resultados da análise cromática aplicada aos três casos representativos, incluindo a paleta de cores identificadas, o gráfico de distribuição percentual e a reconstrução visual da imagem baseada nos clusters de cores.

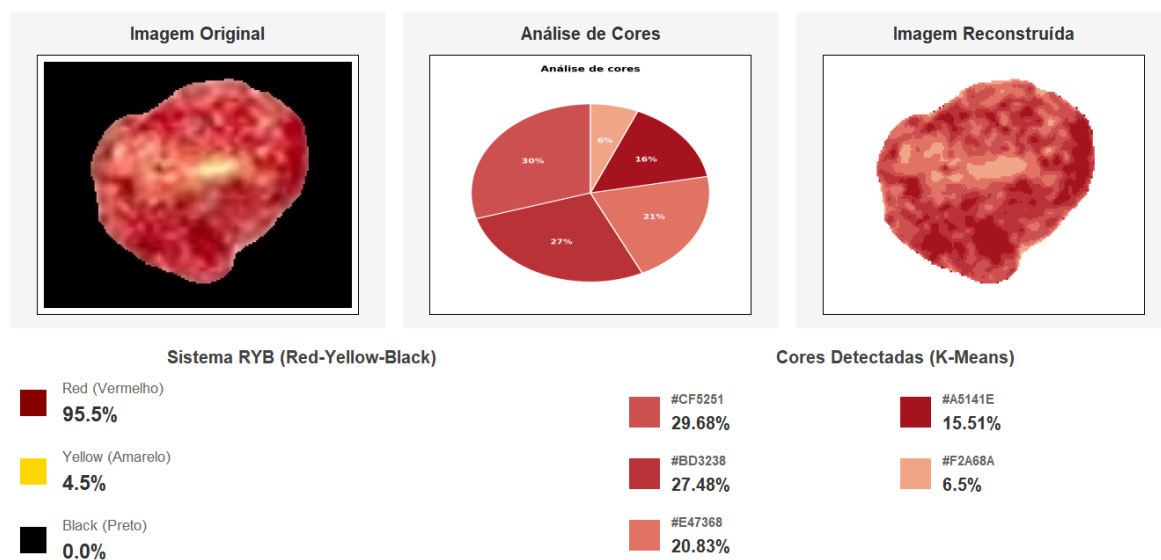
Figura 28: Visualização das métricas calculadas



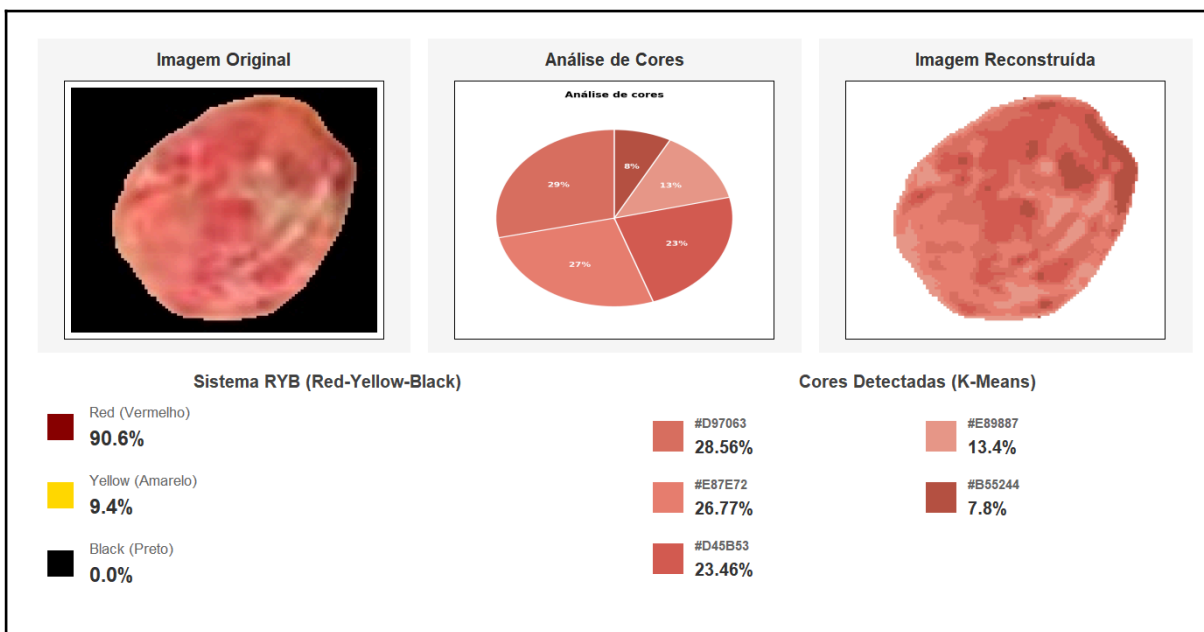
(b) Caso B



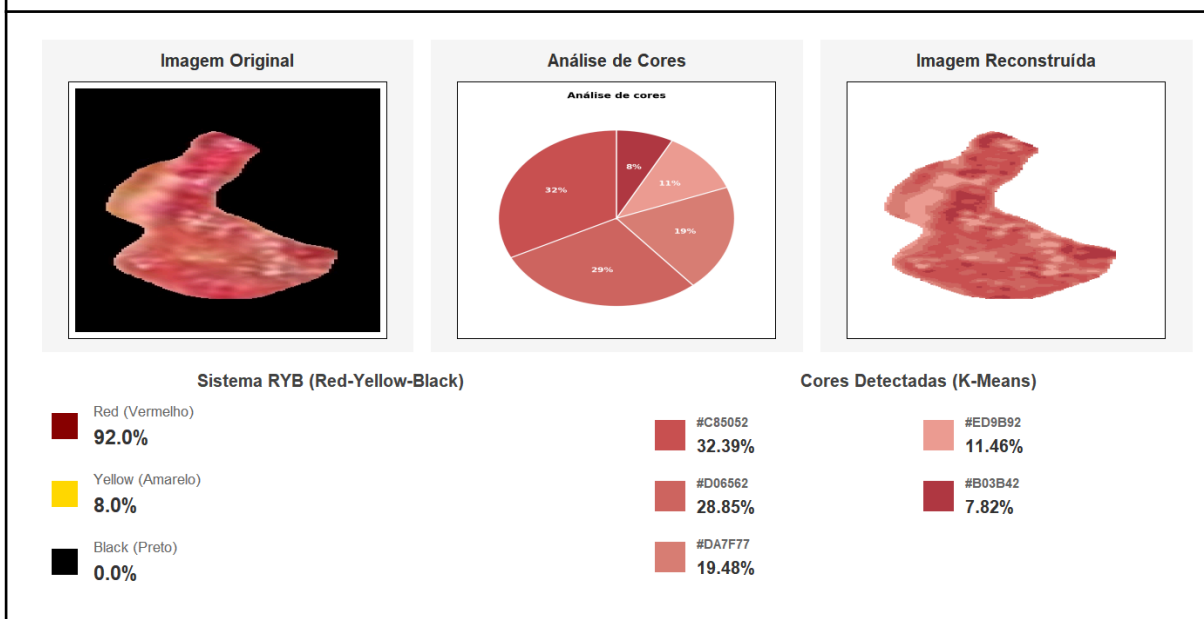
(c) Caso C



(d) Caso D



(e) Caso E



Fonte: Autores

O Caso A apresenta distribuição cromática caracterizada por presença significativa de tonalidades escuras (54,1% classificadas como Black/Preto) e tonalidades avermelhadas (45,9% classificadas como Red/Vermelho), com ausência de tonalidades amareladas. A predominância de cores escuras sugere presença de tecido necrosado ou desvitalizado, enquanto as áreas vermelhas indicam tecido de granulação. A imagem reconstruída evidencia claramente a distribuição espacial dessas tonalidades, mostrando que as áreas mais escuras concentram-se predominantemente em determinadas regiões do ferimento.

A análise pelo K-Means identificou quatro clusters principais com as seguintes proporções: 35,53% (#442F47), 18,59% (#7F6E5F), 17,16% (#D1AD4E), e 14,51% (#8F7179). Esta diversidade de tonalidades, mesmo dentro das categorias RYB, reflete a complexidade cromática real do ferimento.

O Caso B apresenta distribuição cromática significativamente diferente, com predominância de tonalidades amareladas (53,9%) e vermelhas (46,1%), sem presença de áreas classificadas como pretas. Esta composição cromática sugere ferimento com presença importante de exsudato ou tecido fibrinoso (tonalidades amarelas) combinado com tecido de granulação (tonalidades vermelhas), indicando processo cicatricial em andamento sem presença significativa de necrose.

O K-Means identificou quatro clusters dominantes: 29,27% (#F7DDB2), 27,79% (#F9C289), 16,77% (#D47470), e 11,42% (#8F4D52). A imagem reconstruída mostra distribuição relativamente homogênea das tonalidades mais claras (bege e laranja) por toda a extensão do ferimento, com concentrações de vermelho mais intenso em regiões específicas, possivelmente correspondendo a áreas de maior vascularização ou tecido de granulação mais maduro.

O Caso C apresenta predominância marcante de tonalidades vermelhas (95,5%), com presença mínima de amarelo (4,5%) e ausência de tonalidades pretas. Esta distribuição indica ferimento predominantemente composto por tecido de granulação saudável, sugerindo processo cicatricial ativo e favorável. A pequena proporção de amarelo pode corresponder a áreas com exsudato leve ou fibrina nas bordas, conforme observado visualmente.

A análise pelo K-Means revelou quatro tonalidades vermelhas distintas: 29,68% (#CF6261), 27,48% (#BD0328), 20,83% (#E47789), e 6,5% (#F2468A). A presença de múltiplas tonalidades de vermelho, mesmo dentro da mesma categoria RYB, demonstra a capacidade do algoritmo de capturar variações cromáticas sutis que podem ter relevância clínica. A imagem reconstruída mostra distribuição dessas tonalidades de forma relativamente uniforme, com leve concentração de tons mais claros em determinadas regiões.

O Caso D apresenta distribuição cromática caracterizada por predominância de tonalidades vermelhas (90.6%) e presença moderada de amarelo (9.4%), com ausência de tonalidades pretas. Esta composição sugere ferimento com tecido de granulação predominante (áreas vermelhas) combinado com regiões de exsudato ou fibrina (áreas amareladas), indicando processo cicatricial em andamento.

A análise pelo K-Means identificou três clusters principais com as seguintes proporções: 28.56% (#D97063), 26.77% (#E87E72), e 23.46% (#D45B53). Esta distribuição de tonalidades vermelhas com variações sutis de intensidade reflete a heterogeneidade do tecido de granulação ao longo da extensão linear do ferimento. A imagem reconstruída mostra distribuição relativamente uniforme das tonalidades avermelhadas pela maior parte da lesão, com as áreas amareladas concentrando-se principalmente na extremidade superior, correspondendo à região que apresentou características visuais distintas durante a segmentação.

O Caso E apresenta distribuição cromática com forte predominância de tonalidades vermelhas (92.0%) e presença de amarelo (8.0%), sem áreas classificadas como pretas. Esta composição indica ferimento predominantemente composto por tecido de granulação, com presença de áreas amareladas possivelmente correspondendo a fibrina ou exsudato, conforme observado visualmente na análise morfológica.

A análise pelo K-Means revelou três clusters principais: 32.39% (#C85052), 28.85% (#D06562), e 19.48% (#DA7F77). A presença dessas tonalidades vermelhas distintas demonstra variações cromáticas ao longo do ferimento, com áreas de vermelho mais intenso alternando com tonalidades mais claras. A imagem reconstruída evidencia distribuição heterogênea dessas tonalidades, com concentrações de tons mais escuros em determinadas regiões e áreas mais claras em outras, refletindo a complexidade do processo cicatricial e a presença de diferentes tipos de tecido dentro da lesão.

O algoritmo de análise cromática demonstrou capacidade de identificar e quantificar objetivamente as cores presentes nos três casos representativos, revelando diferenças significativas entre eles. A comparação entre os casos ilustra a utilidade clínica potencial da quantificação cromática: o Caso A, com 54,1% de tonalidades escuras, claramente difere dos Casos B e C em termos de composição cromática, sugerindo diferentes estágios ou características do processo de cicatrização.

A categorização segundo o sistema RYB fornece interpretação clínica simplificada e alinhada com práticas estabelecidas. O Caso C, com 95,5% de vermelho, sugere prognóstico favorável com predominância de tecido de granulação saudável. O Caso B, com distribuição equilibrada entre vermelho e amarelo, indica

processo cicatricial em curso com presença de exsudato. O Caso A, com presença significativa de preto (54,1%), sinaliza necessidade de atenção clínica devido à proporção de tecido necrosado ou desvitalizado.

A quantificação automática de cores oferece vantagens significativas em relação à avaliação visual subjetiva: fornece valores numéricos reprodutíveis, elimina variabilidade do observador, e permite acompanhamento objetivo de mudanças cromáticas ao longo do tempo. A comparação entre os três casos demonstra como diferenças cromáticas objetivas podem refletir diferentes estados clínicos dos ferimentos.

A imagem reconstruída, em particular, demonstrou-se ferramenta útil para visualização da distribuição espacial das cores identificadas. No Caso A, por exemplo, torna evidente a localização das áreas escuras; no Caso B, mostra a distribuição relativamente homogênea das tonalidades claras; e no Caso C, revela a uniformidade das tonalidades vermelhas por toda a extensão da lesão. Além de ser uma ferramenta de validação da detecção das cores em si, ao passo que reproduz a imagem original.

Algumas considerações importantes foram identificadas durante a análise dos casos:

- Dependência da iluminação: Embora o uso de espaços de cores como HSV e Lab suavize parcialmente os efeitos de variações de iluminação, condições extremas ainda podem afetar a identificação precisa.
- Subjetividade na categorização RYB: A conversão de cores contínuas em categorias discretas envolve definição de limiares, por esse motivo pode não capturar toda a nuance cromática, por esse motivo são retornadas também os clusters identificados pelo K-Means
- Validação clínica: A correspondência entre as distribuições cromáticas quantificadas e sua interpretação clínica requer validação por profissionais de saúde.

Apesar dessas considerações, o algoritmo de análise cromática demonstrou-se funcionalmente adequado para fornecer quantificação objetiva e reprodutível das cores presentes em ferimentos cutâneos. A abordagem oferece informação complementar às métricas de área e forma, contribuindo para caracterização mais completa das lesões. Reiterando, a solução deve ser utilizada

como ferramenta de auxílio ao profissional da saúde e não para diagnósticos sem supervisão

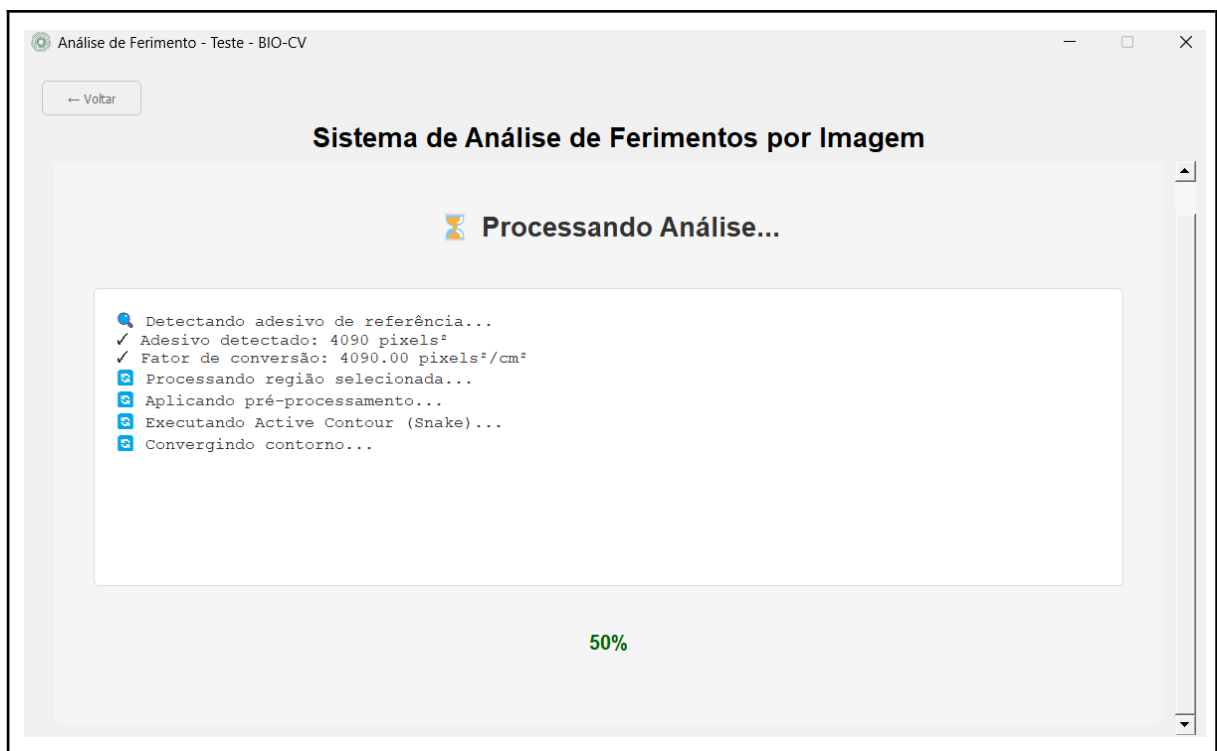
5.3 Apresentação dos Resultados Integrados do Sistema

As seções anteriores apresentaram a validação individual de cada algoritmo de processamento de imagem implementado no Bio-CV. Esta seção demonstra o funcionamento integrado do sistema através de um caso demonstrativo completo, ilustrando como todas as funcionalidades operam de forma coordenada desde a captura da imagem até a apresentação dos resultados finais.

O sistema Bio-CV opera através de um pipeline sequencial automatizado, conforme descrito na seção 4 (Solução). Uma vez que o usuário carrega a imagem e seleciona a região de interesse, o processamento ocorre automaticamente, executando as etapas de segmentação, cálculo de métricas e análise cromática de forma integrada.

A figura 29 apresenta a interface principal do sistema durante o processo de análise de um ferimento.

Figura 29: Interface de processamento do Bio-CV

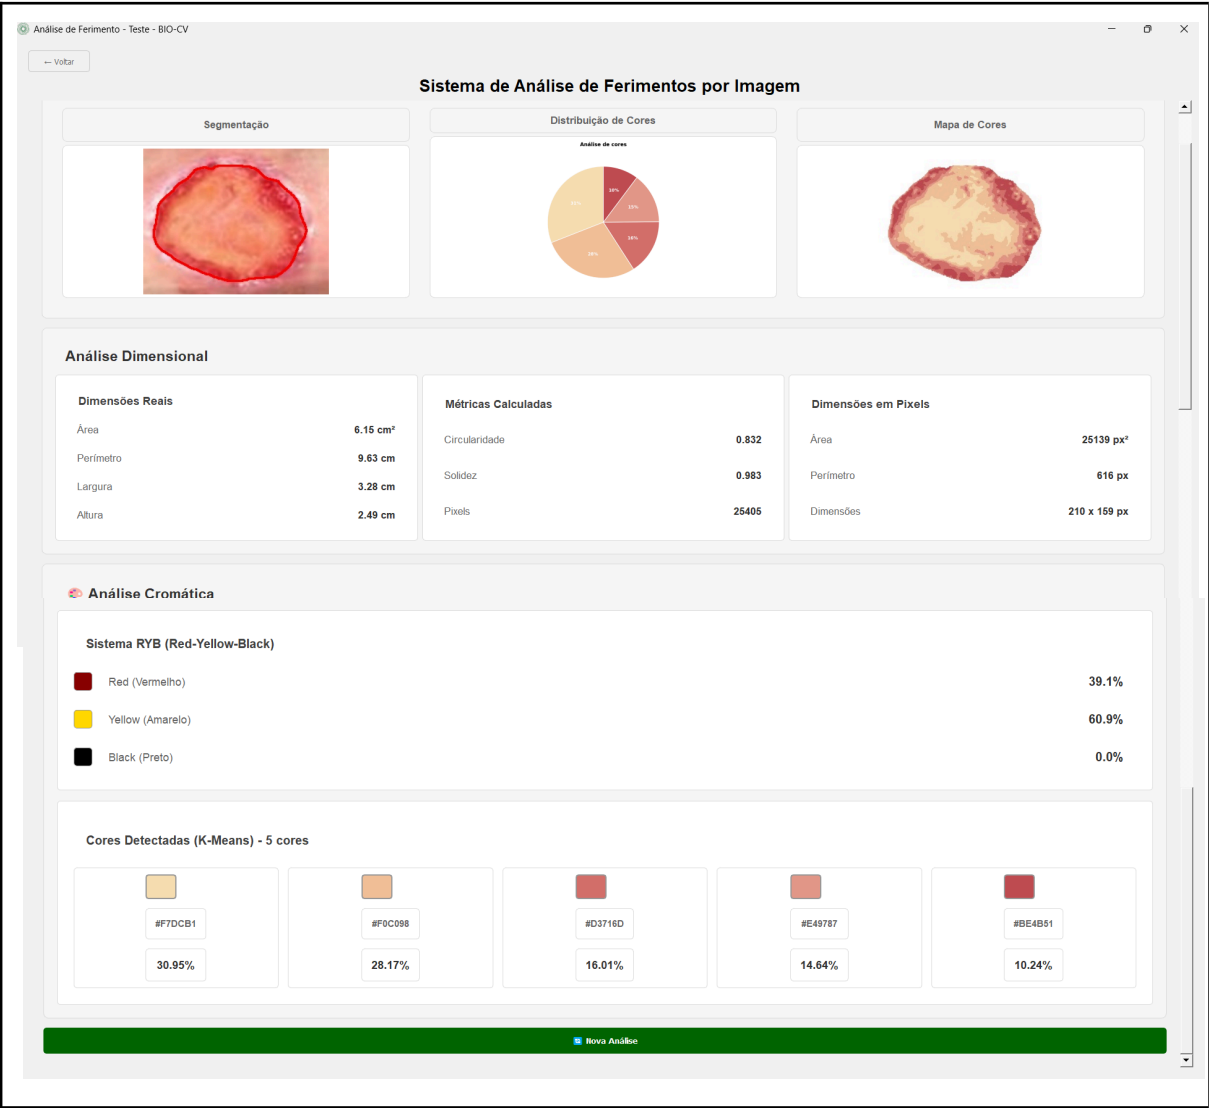


Fonte: Autores

Após a conclusão do processamento automático, o sistema apresenta os resultados de forma integrada através da interface de resultados, que consolida todas as análises realizadas em uma única tela.

A figura 30 apresenta a interface completa de resultados do Bio-CV, onde todas as informações geradas pelos três algoritmos são apresentadas de forma organizada e acessível.

Figura 30: Interface de resultados completos do sistema Bio-CV



Fonte: Autores

A interface de resultados está organizada em seções distintas que apresentam:

- Visualizações gráficas (parte superior): Três componentes visuais apresentados lado a lado - a imagem original do ferimento isolado, o gráfico

de distribuição cromática em formato de pizza, e a imagem reconstruída onde cada pixel é colorido de acordo com o cluster identificado pelo algoritmo K-Means. Esta apresentação visual permite compreensão imediata tanto da aparência real do ferimento quanto de sua composição cromática quantificada.

- **Classificação cromática:** O sistema apresenta a distribuição segundo o sistema RYB (Red-Yellow-Black), indicando os percentuais de tecido de granulação (vermelho), exsudato ou tecido desvitalizado (amarelo), e necrose (preto). Adjacente à classificação RYB, é exibida a paleta detalhada das cores dominantes identificadas pelo K-Means, com seus códigos hexadecimais e percentuais específicos, oferecendo caracterização cromática em dois níveis de detalhamento.
- **Métricas em pixels:** Apresenta as medidas brutas obtidas diretamente do processamento da imagem: área em pixels quadrados, perímetro em pixels, quantidade total de pixels do ferimento, e dimensões do bounding box (menor retângulo que envolve o ferimento). Estas informações são úteis para referência técnica e verificação do processamento.
- **Métricas calculadas:** Exibe os índices de circularidade e solidez, ambos variando de 0 a 1. A circularidade indica quão próxima a forma do ferimento está de um círculo perfeito (valor 1 = círculo perfeito, valores menores = formas mais irregulares ou alongadas). A solidez indica o grau de "preenchimento" da forma (valor 1 = forma totalmente convexa, valores menores = presença de reentrâncias ou concavidades).
- **Dimensões reais calibradas:** Apresenta as medidas clinicamente mais relevantes, convertidas para unidades reais através do fator de calibração obtido pelo adesivo de referência: área total em centímetros quadrados, perímetro em centímetros, e dimensões aproximadas (largura e altura) em centímetros. Estas são as métricas primárias para acompanhamento clínico da evolução do ferimento. Esta organização permite acesso rápido às informações mais relevantes clinicamente (área em cm², classificação RYB) mantendo disponíveis os detalhes técnicos para análises mais aprofundadas quando necessário.

A partir da interface apresentada na figura 30, é possível observar concretamente os resultados obtidos pelo sistema Bio-CV em um caso real de processamento. A análise dimensional revela informações precisas sobre as características geométricas do ferimento processado. O sistema calculou uma área real de 6.15 centímetros quadrados, com perímetro de 9.63 centímetros, indicando um ferimento de dimensões moderadas.

As medidas de largura e altura, 3.28 centímetros e 2.49 centímetros respectivamente, sugerem uma forma ligeiramente alongada no eixo horizontal. Em termos de resolução digital, o ferimento ocupa 25405 pixels da imagem capturada, distribuídos em uma área de 25139 pixels quadrados com perímetro de 616 pixels, e dimensões em pixels de 210 por 159.

As métricas calculadas fornecem informações adicionais sobre a morfologia do ferimento. O índice de circularidade de 0.832 indica que a forma se aproxima razoavelmente de um círculo, embora não seja perfeitamente circular, sugerindo algum grau de irregularidade nas bordas.

A solidez de 0.983 demonstra que o ferimento possui contorno relativamente convexo, com poucas reentrâncias ou concavidades significativas, o que pode ser um indicador positivo do processo de cicatrização. Estes índices morfométricos, combinados com as dimensões absolutas, permitem caracterização objetiva da geometria da lesão.

A análise cromática automática revelou características importantes sobre a composição tecidual do ferimento. Segundo a classificação RYB, o sistema identificou 39.1% de componente vermelho, associado ao tecido de granulação saudável, e 60.9% de componente amarelo, relacionado à presença de exsudato ou tecido desvitalizado. Notavelmente, não foi detectada presença de tecido necrótico (componente preto), o que pode indicar um ferimento em processo ativo de cicatrização, sem áreas de necrose estabelecida. Esta distribuição cromática quantificada oferece base objetiva para avaliação do estado evolutivo da lesão.

O algoritmo K-Means identificou cinco cores dominantes na imagem do ferimento, fornecendo detalhamento adicional da composição cromática. A cor mais prevalente, com código hexadecimal #F7DCB1 e representando 30.95% da área, corresponde a tonalidade bege clara. A segunda cor mais frequente, #F0C098 com 28.17%, apresenta tom pêssego claro. As tonalidades avermelhadas aparecem em

três intensidades distintas: #D3716D com 16.01%, #E49787 com 14.64%, e #BE4B51 com 10.24%, variando de vermelho rosado a vermelho mais intenso. Esta paleta detalhada complementa a classificação RYB simplificada, permitindo análise cromática em múltiplos níveis de granularidade conforme a necessidade clínica ou de pesquisa.

A integração de todas essas informações em uma única interface demonstra a capacidade do sistema *Bio-CV* de realizar análise abrangente e multidimensional de ferimentos cutâneos. De forma que uma única análise disponibilizou todas as informações discorridas nos parágrafos anteriores.

A disponibilidade simultânea de métricas simplificadas para uso clínico imediato e de dados técnicos detalhados para análises aprofundadas torna o sistema versátil o suficiente para atender diferentes necessidades, desde o acompanhamento de rotina em ambiente clínico até aplicações em pesquisa científica sobre processos de cicatrização.

6. Considerações Finais

O presente trabalho apresentou o desenvolvimento do Bio-CV, um sistema de visão computacional para análise automatizada de ferimentos cutâneos, integrando técnicas de processamento de imagem e para fornecer avaliações objetivas e padronizadas de lesões. A pesquisa demonstrou que é possível substituir métodos tradicionais de avaliação, frequentemente subjetivos e imprecisos, por uma abordagem tecnológica que oferece mensuração quantitativa, reproduzível e acessível.

A implementação dos três algoritmos principais - segmentação por limiarização de cor, detecção e calibração através de marcador de referência, e classificação cromática pelo método K-Means - mostrou-se eficaz na extração de informações relevantes sobre dimensões reais, morfologia e cromática do ferimento.

A utilização de um adesivo como elemento de calibração revelou-se uma solução prática e de baixo custo, permitindo conversão precisa de medidas digitais para unidades reais sem necessidade de equipamentos especializados. A interface desktop desenvolvida garante acesso simplificado aos dados, possibilitando uso em diferentes contextos clínicos.

Os resultados obtidos evidenciam que o sistema consegue realizar análises de ferimentos de forma rápida e intuitiva, apresentando métricas dimensionais calibradas em centímetros, índices como circularidade e solidez, e distribuição cromática segundo o sistema RYB amplamente utilizado na avaliação clínica de feridas. A classificação detalhada de cores dominantes pelo K-Means complementa a análise, oferecendo granularidade adicional quando necessária para pesquisa ou acompanhamento mais minucioso.

A padronização das medições favorece a comunicação entre profissionais de saúde e a comparação temporal da evolução das lesões, fundamentais para tomada de decisões terapêuticas baseadas em evidências. Além disso, a documentação digital automática facilita a manutenção de registros completos e organizados, atendendo tanto necessidades assistenciais quanto de pesquisa científica.

É preciso considerar que apesar dos resultados positivos, o trabalho apresenta limitações que devem ser consideradas. O sistema foi desenvolvido e testado com conjunto limitado de imagens, sendo necessária validação mais ampla com diferentes tipos de ferimentos, condições de iluminação e características de pele.

A validação quantitativa comparativa – que envolveria a comparação direta entre as medições automatizadas pelo *Bio-CV* e mensurações reais obtidas por métodos padronizados em ambiente clínico controlado poderá ser objeto de estudos futuros.

Juntamente a sugestão do parágrafo anterior há a expansão do banco de dados de imagens para validação mais robusta dos algoritmos, incluindo diferentes etnias, tipos de lesão e estágios de cicatrização, bem como estudos clínicos comparativos entre avaliações manuais e automatizadas seriam fundamentais para validação científica do método.

Retomando a hipótese inicial deste trabalho, que propunha ser possível desenvolver um sistema de visão computacional capaz de analisar automaticamente ferimentos cutâneos a partir de imagens fotográficas, fornecendo medições objetivas de dimensões e classificação cromática de forma acessível e sem necessidade de equipamentos especializados, pode-se afirmar que ela foi plenamente confirmada.

O *Bio-CV* comprovou, através de sua implementação funcional e dos resultados apresentados, que técnicas consolidadas de processamento de imagem,

são capazes de extrair informações quantitativas precisas sobre ferimentos cutâneos de maneira automática e reprodutível. O sistema não pretende substituir a avaliação clínica do profissional de saúde, mas sim atuar como ferramenta auxiliar que complementa o julgamento clínico com dados objetivos e padronizados.

Embora desafios permaneçam em termos de validação clínica ampla e refinamento contínuo dos algoritmos, o Bio-CV demonstra que a visão computacional pode efetivamente apoiar profissionais da saúde no acompanhamento de ferimentos cutâneos, fornecendo subsídios mensuráveis que auxiliam na tomada de decisões e na documentação sistematizada da evolução das lesões.

7. Referências

ALONSO, M. C. et al. Comparison of Wound Surface Area Measurements Obtained Using Clinically Validated Artificial Intelligence-Based Technology Versus Manual Methods and the Effect of Measurement Method on Debridement Code Reimbursement Cost. **Wounds**, v. 35, n. 10, p. E330-E338, out. 2023.

BARBOSA, Fellipe Matheus Costa. **Medição precisa de áreas de feridas crônicas usando Structure from Motion**. 2020. 111 f. Dissertação (Mestrado em Sistemas e Computação) – Centro de Ciências Exatas e da Terra, Universidade Federal do Rio Grande do Norte, Natal, 2020.

BARELLI, F. **Introdução à visão computacional**: uma abordagem prática com Python e OpenCV. São Paulo: Casa do Código, 2018.

CALIRI, M. H. L. Galeria de fotografias. In: GRUPO DE ESTUDOS E PESQUISA EM SEGURANÇA DO PACIENTE. **Feridas crônicas**. Ribeirão Preto, 2020.

DELAI, R. L.; COELHO, A. D. **Visão computacional com a OpenCV**: material apostilado e veículo seguidor autônomo. São Caetano do Sul: Escola de Engenharia Mauá, [s.d.]. Apostila.

ESPÍRITO SANTO, P. F. et al. Uso da ferramenta Pressure Ulcer Scale for Healing para avaliar a cicatrização de úlcera crônica de perna. **Revista Brasileira de Cirurgia Plástica**, v. 28, n. 1, p. 133-141, mar. 2013.

GOYAL, M. et al. Recognition of ischaemia and infection in diabetic foot ulcers: Dataset and techniques. **Computers in Biology and Medicine**, v. 117, article 103616, 2020.

GUO, S.; DIPIETRO, L. A. Factors Affecting Wound Healing. **Journal of Dental Research**, v. 89, n. 3, p. 219-229, 2010.

KUNDU, R. Image Processing: Techniques, Types, & Applications. **V7 Labs Blog**, 3 ago. 2024. Disponível em: <https://www.v7labs.com/blog/image-processing-guide>. Acesso em: 20 nov. 2025.

LEE, C. H. et al. Automated Image-Based Wound Area Assessment in Outpatient Clinics Using Computer-Aided Methods: A Development and Validation Study. **Journal of Clinical Medicine**, v. 13, n. 11, 2024.

LI, K.-C.; LEE, Y.-H.; LIN, Y.-H. Automated Image-Based Wound Area Assessment in Outpatient Clinics Using Computer-Aided Methods: A Development and Validation Study. **Medicina**, v. 61, n. 6, p. 1099, 2025.

LISBOA, K. O. et al. A história da telemedicina no Brasil: desafios e vantagens. **Saúde e Sociedade**, v. 32, n. 1, 2023.

MANDELBAUM, S. H.; DI SANTIS, É. P.; MANDELBAUM, M. H. S. Cicatrização: conceitos atuais e recursos auxiliares. **Anais Brasileiros de Dermatologia**, v. 78, n. 4, p. 393-410, 2003.

MARIA DA SILVA, G. et al. Conhecimento dos profissionais de saúde quanto ao processo cicatricial de feridas. **Congresso Brasileiro de Estomaterapia**, [S. l.], 2024. Disponível em: <https://anais.sobest.com.br/cbe/article/view/631>. Acesso em: 15 jan. 2025.

MARQUES DA SILVA, Ana Maria; PATROCÍNIO, Ana Cláudia; SCHIABEL, Homero. Processamento e Análise de Imagens Médicas. **Revista Brasileira de Física Médica**, [S. l.], v. 13, n. 1, p. 34–48, 2019. DOI: 10.29384/rbfm.2019.v13.n1.p34-48. Disponível em: <https://www.rbfm.org.br/rbfm/article/view/525>. Acesso em: 14 fev. 2025.

MIRZAALIAN DASTJERDI, H. et al. Measuring Surface Area of Skin Lesions with 2D and 3D Algorithms. **International Journal of Biomedical Imaging**, v. 2019, article 4035148, 2019.

MONTEIRO DE MENEZES, Stéfani; KELLY BORGES FONSECA, Anny; MOREIRA DE MATOS, Neuza. Perfil de pacientes com lesões cutâneas hospitalizados em uma unidade de internação de clínica médica. **Health Residencies Journal**, [S. l.], v. 3, n. 15, p. 95–108, 2022. DOI: 10.51723/hrj.v3i15.426. Disponível em: <https://hrj.emnuvens.com.br/hrj/article/view/426>. Acesso em: 8 jan. 2025.

NAGLE, S. M.; STEVENS, K. A.; WILBRAHAM, S. C. Wound Assessment. In: **StatPearls**. Treasure Island (FL): StatPearls Publishing, 2023. Disponível em: <https://www.ncbi.nlm.nih.gov/books/NBK482198/>. Acesso em: 5 jan. 2025.

PONTES, W. F. **Tecnologias para mensuração de feridas crônicas**: revisão integrativa. 2023. Trabalho de Conclusão de Curso (Graduação em Enfermagem) – Escola de Enfermagem, Universidade Federal de Alagoas, Maceió, 2023.

SABRY, F. **Visão computacional**: explorando percepção inteligente e tomada de decisão em sistemas autônomos. [S.l.]: One Billion Knowledgeable, 2024. (Ciência da Robótica, v. 36).

SANTOS, Isabel et al. Usabilidade do sistema de classificação de feridas por cor – ryb wound classification system. **Ciência, Cuidado e Saúde**, v. 16, n. 4, 2017. DOI: 10.4025/cienccuidsaude.v16i4.34436.

SHI, C. et al. Assessing chronic wound tissue composition using smartphone image analysis and color-based clustering. **International Wound Journal**, v. 16, n. 1, p. 211-220, 2019.

SOMMERVILLE, I. **Engenharia de software**. Tradução de Ivan Bosnic e Kalinka G. de O. Gonçalves. 9. ed. São Paulo: Pearson Prentice Hall, 2011.

TAVARES, A. R. et al. Visão computacional na saúde: revisão de métodos e desafios educacionais para integração multidisciplinar. **Cuadernos de Educación y Desarrollo**, [S. l.], v. 16, n. 13, p. e7088, 2024. DOI: 10.55905/cuadv16n13-169. Disponível em: <https://ojs.cuadernoseducacion.com/ojs/index.php/ced/article/view/7088>. Acesso em: 14 fev. 2025.

TOTTOLI, E. M. et al. Skin Wound Healing Process and New Emerging Technologies for Skin Wound Care and Regeneration. **Pharmaceutics**, v. 12, n. 8, p. 735, 5 ago. 2020. DOI: 10.3390/pharmaceutics12080735. PMID: 32764269; PMCID: PMC7463929.

TUTORIAL: introdução à visão computacional usando OpenCV. **Revista de Informática Teórica e Aplicada**, v. 16, n. 1, mar. 2010. DOI: 10.22456/2175-2745.11477. Disponível em: <https://seer.ufrgs.br/index.php/rita/article/view/11477>. Acesso em: 20 fev. 2025.

VIGNERON, A.; DOMINGOS, C. **Lesão cutânea**: abordagem do enfermeiro direcionada aos cuidados. 2021. Trabalho de Conclusão de Curso (Graduação em Enfermagem) – Faculdade de Filosofia, Ciências e Letras Dom Bosco, 2021.

WANG, C. et al. Fully automatic wound segmentation with deep convolutional neural networks. **Scientific Reports**, v. 10, n. 1, p. 21897, 2020. DOI: <https://doi.org/10.1038/s41598-020-78799-w>.

WANG, L. et al. A smartphone-based multi-functional continuous monitoring and analysis system for diabetic foot ulcers. **Journal of Diabetes Science and Technology**, v. 10, n. 4, p. 952-961, 2016.

WEIGELT, M. A. et al. Advanced Wound Diagnostics: Toward Transforming Wound Care into Precision Medicine. **Advanced Wound Care**, v. 11, n. 6, p. 330-359, 2022. DOI: 10.1089/wound.2020.1319.

WU, W. L. et al. The APD Skin Monitoring App for wound monitoring: Image processing, area plot, and colour histogram. **Scientific Phone Apps and Mobile Devices**, v. 5, article 3, 2019.

YADAV, M. K. et al. Segmentation of chronic wound areas by clustering techniques using selected color space. **Journal of Medical Imaging and Health Informatics**, v. 3, n. 1, p. 22-29, 2013.

ZHU, X. et al. Health-related quality of life and chronic wound characteristics among patients with chronic wounds treated in primary care: A cross-sectional study in Singapore. **International Wound Journal**, v. 19, n. 5, p. 1121-1132, 2022.