

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
COORDENAÇÃO DE CIÊNCIA DA COMPUTAÇÃO

RAÍSSA MACEDO PEREIRA

**ANÁLISE DE TÉCNICAS DE
PRÉ-PROCESSAMENTO PARA A
SEGMENTAÇÃO DE IMAGENS DE
VITILIGO**

SANTA HELENA

2021

RAISSA MACEDO PEREIRA

**ANÁLISE DE TÉCNICAS DE PRÉ-PROCESSAMENTO PARA A SEGMENTAÇÃO
DE IMAGENS DE VITILIGO**

Trabalho de conclusão de curso de graduação
apresentada como requisito para obtenção do título de
Bacharel em Ciência da Computação da Universidade
Tecnológica Federal do Paraná (UTFPR).
Orientador: Profa. Dra. Arlete Teresinha Beuren.

SANTA HELENA

2021



**Ministério da Educação
Universidade Tecnológica Federal do Paraná
Câmpus Santa Helena**



RAISSA MACEDO PEREIRA

ANÁLISE DE TÉCNICAS DE PRÉ-PROCESSAMENTO PARA A SEGMENTAÇÃO DE IMAGENS DE VITILIGO

Trabalho de conclusão de curso de graduação apresentada como requisito para obtenção do título de Bacharel em Ciência da Computação da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Segurança de redes de computadores.

Data da aprovação: 21 de maio de 2021

Prof^ª. Arlete Teresinha Beuren, Doutorado – Universidade Tecnológica Federal do Paraná

Prof. Anderson Brilhador, Mestrado – Universidade Tecnológica Federal do Paraná

Prof^ª. Glória Patrícia López Sepúlveda, Doutorado – Universidade Tecnológica Federal do Paraná

Dedico este trabalho a Deus. Sem ele
nada seria possível.

AGRADECIMENTOS

A Deus que com sua infinita sabedoria foi um verdadeiro guia nessa minha jornada.

Aos meus pais e meu irmão que sempre me apoiaram e deram todo suporte necessário para que eu pudesse chegar até aqui.

Aos meus amigos que sempre estiveram presentes direta ou indiretamente em todos os momentos de minha formação.

A minha orientadora Profa. Dra. Arlete Teresinha Beuren, pois sem seus ensinamentos, conselhos, suporte e incentivos não seria capaz de concluir mais essa jornada na minha vida.

A todos os meus professores da graduação, que foram de fundamental importância na construção da minha vida profissional.

A persistência é o caminho do êxito.

Charles Chaplin

RESUMO

MACEDO, Raíssa. Análise de técnicas de pré-processamento para a segmentação de imagens de vitiligo. 2021. 62f. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) – Universidade Tecnológica Federal do Paraná. Santa Helena.

O vitiligo é uma doença identificada pela perda da pigmentação da pele, devido a diminuição ou ausência de melanócitos. Com o intuito de avaliar essas imagens de vitiligo, este trabalho apresenta algumas técnicas de pré-processamento com índices de branco e segmentação de imagens com o algoritmo *k-means* e algoritmo de Otsu. A avaliação dessas técnicas foi realizada por meio de quatro métricas: *accuracy*, *precision*, *f1-score* e *recall*. Os melhores resultados de índices de branco com segmentação *k-means* obtiveram valores entre 90 e 91% de *accuracy* e 90 a 94% de *f1-score*.

Palavras-chave: Vitiligo. Segmentação de imagens. Otsu. *K-means*. Pré-processamento. Índices de branco.

ABSTRACT

MACEDO, Raíssa. Analysis of pre-processing techniques for the transformation of vitiligo images. 2021. 62f. Course Conclusion Paper (Bachelor of Computer Science) - Federal Technological University of Paraná. Saint Helen.

Vitiligo is a disease identified by the loss of skin pigmentation, due to the decrease or absence of melanocytes. In order to evaluate these vitiligo images, this work presents some pre-processing techniques with white indexes and related images with the k-means and Otsu algorithms. The evaluation of these techniques was performed using four metrics: accuracy, precision, f1-score, and recall. The best results of white indexes with associated k-means obtained values between 90 and 91% of accuracy and 90 to 94% of f1-score.

Keywords: *Vitiligo. Image segmentation. Otsu. K-means. Pre-processing White index.*

LISTA DE ILUSTRAÇÕES

1	Lesão de vitiligo.	15
2	Fluxograma das etapas do processamento de imagens.	18
3	Aquisição de imagens.	19
4	Imagem original (a); Imagem processada com filtro de mediana (b).	21
5	Iterações do <i>k-means</i>	27
6	Exemplo de matriz de confusão.	28
7	Protocolo dos experimentos.	42
8	Imagens originais e respectivas <i>groundtruth</i>	43
9	Segmentação com o método de Otsu.	44
10	Segmentação com o algoritmo <i>k-means</i>	45
11	Resultados do pré-processamento dos índices de branco.	47
12	Resultados com o filtro de mediana.	48
13	Aplicação do algoritmo <i>k-means</i> + índice ASTME.	49
14	Aplicação do algoritmo <i>k-means</i> + índice LANIER.	49
15	Resultado do método Otsu não bimodal.	49
16	Resultado do método Otsu bimodal.	50
17	Segmentação com algoritmo <i>k-means</i> na imagem original.	50
18	Segmentação com algoritmo de Otsu na imagem original.	51
19	Segmentação com algoritmo de Otsu com índice de branco.	51
20	Segmentação com algoritmo de Otsu com índice + mediana.	52
21	Segmentação com índice + <i>k-means</i>	53

22	Segmentação com índice + mediana + <i>k-means</i>	54
----	---	----

LISTA DE TABELAS E QUADROS

1	Tabela de valores de a e b, coeficientes da equação 2.3.	22
2	Valores para x_0 e y_0 que são as coordenadas de cromaticidade da equação 5.	22
3	Estado da arte	35
4	Avaliação da segmentação com <i>k-means</i> e Otsu.	50
5	Avaliação dos índices de branco + Otsu.	51
6	Avaliação dos índices de branco + mediana + Otsu.	52
7	Avaliação dos índices de branco + <i>k-means</i>	53
8	Avaliação dos índices de branco + mediana + <i>k-means</i>	54
9	Comparação dos métodos.	55

LISTA DE ABREVIATURAS E SIGLAS

ADRD	<i>Attention-Aware DenseNet</i>
CNN	Rede Neural Convulucional
CAM	Mapa de Ativação de Classe
Cycle Gan	<i>Cycle-Consistent Adversarial Networks</i>
DCT	<i>Discrete Cosine Transform</i>
GLCM	Matriz de co-ocorrências de níveis de cinza
ICA	<i>Component Analysis</i>
IoU	Métrica da Intersecção sobre União
LBP	<i>Local binary patterns</i>
MOFS	<i>Multi Object Fuzzy Segmentation</i>
PCA	<i>Principal Component Analysis</i>
PGA	<i>Physician Global Assessment</i>
RNAs	Redes Neuraís Artificias
SVM	<i>Support Vector Machine</i>
TFD	Transformada de Fourier Discreta

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVOS	15
1.1.1	Geral	16
1.1.2	Específicos	16
1.2	CONTRIBUIÇÕES DO TRABALHO	16
1.3	JUSTIFICATIVA	17
1.4	DELIMITAÇÕES DO TRABALHO	17
2	REVISÃO DA LITERATURA	18
2.1	PROCESSAMENTO DE IMAGENS	18
2.1.1	Aquisições de imagens digitais	19
2.1.2	Pré-processamento	19
2.1.2.1	Suavização de imagens	20
2.1.2.2	Índices de Branco	21
2.1.3	Segmentação	25
2.1.3.1	<i>K-means</i>	26
2.2	MÉTRICAS DE AVALIAÇÃO	27
2.2.1	Métrica <i>Precision</i>	27
2.2.2	Métrica <i>Accuracy</i>	28
2.2.3	Métrica <i>Recall</i>	28
2.2.4	Métrica <i>F1-Score</i>	29

2.3	ESTADO DA ARTE	29
3	METODOLOGIA	42
3.1	BASE DE IMAGENS	43
3.2	PRÉ-PROCESSAMENTO	43
3.3	SEGMENTAÇÃO	44
3.4	AVALIAÇÃO DA ABORDAGEM PROPOSTA	45
4	ANÁLISE DOS RESULTADOS	47
4.1	Análise das técnicas de pré-processamento	47
4.2	Análise das técnicas de segmentação	48
4.3	Análise das métricas de avaliação	50
5	COMPARAÇÃO DA ABORDAGEM PROPOSTA COM ABOR- DAGENS APRESENTADAS NA LITERATURA	55
6	CONCLUSÃO	56

1 INTRODUÇÃO

O vitiligo é uma doença autoimune conhecida por manchas brancas de diferentes tamanhos e formas que, se não forem tratadas adequadamente, ao decorrer do tempo podem crescer continuamente podendo atingir ambos os sexos e idade (STEINER et al., 2004).

Segundo Nunes e Esser (2011), o vitiligo manifesta-se em 0,5% a 1% da população e ocorre em todas as nacionalidades. A Índia é o país que tem mais casos da doença, cerca de 8,8% da população. A perda de pigmento da pele atinge 50% dos pacientes antes dos 20 anos. A maioria das pessoas com vitiligo, mesmo tendo uma saúde boa, correm um risco maior em terem doenças autoimunes, como diabetes, tireoides, anemia e etc.

A Sociedade Brasileira de Cirurgia Dermatológica (SBCD, 2020), ressalta que, na maioria dos casos o único sintoma do vitiligo são manchas despigmentadas na pele. Há alguns casos de pacientes que relataram sensibilidade e dor na área da lesão, porém, faz-se necessário atendimento psicológico e tratamento, pois os pacientes podem desenvolver sintomas emocionais como, por exemplo, a depressão, baixa autoestima e insegurança por consequência da doença.

O vitiligo possui tratamentos que apresentam excelentes resultados, tendendo a cessar a evolução das lesões mantendo a estabilidade no quadro. Os tratamentos tradicionais são a base de cremes de corticoides, loções e fototerapia, medicamentos como vitamina D e imunossupressores que usam tacrolimo, auxiliando na re-pigmentação das regiões afetadas (SBCD, 2020).

A causa do vitiligo é a perda ou destruição de melancócitos que são as células que produzem melanina que produzem a cor de pele, cabelos e olhos. Os locais mais comuns para o aparecimento das lesões de vitiligo são áreas expostas como a face, pescoço, pálpebras, narinas, pontas dos dedos das mãos e pés, dobras corporais, axilas e virilha (NUNES; ESSER, 2011). A Figura 1 ilustra uma lesão de vitiligo.



Figura 1: Lesão de vitiligo.
Fonte: (OAKLEY, 2015).

Segundo Ballard e Brown (1982), o processamento de imagens tem como objetivo processar automaticamente as imagens e produz uma das principais formas de interpretação. Duas importantes tarefas do processamento de imagens são o pré-processamento e a segmentação das imagens digitais. O pré-processamento tem como principal finalidade a correção de distorções geométricas e remoção de ruído e a segmentação em separar as áreas relacionadas aos objetos representados na imagem, considerando a descontinuidade e a semelhança dessas áreas (BOTELHO, 2014).

No entanto, no campo de pesquisa de doenças de pele pigmentadas, o vitiligo tem a atenção de especialistas por apresentar algumas características semelhantes a outras doenças cutâneas, como baixo contraste, lesões irregulares e extensas. Logo, com intuito de avaliar imagens com lesões de vitiligo, técnicas de pré-processamento e segmentação serão aplicadas neste estudo.

1.1 OBJETIVOS

Expõem-se a seguir o objetivo geral e os objetivos específicos que se pretende atingir neste estudo.

1.1.1 Geral

O objetivo deste trabalho consiste em explorar e avaliar diferentes técnicas de pré-processamentos com índices de branco para a segmentação de lesões de vitiligo e propor a melhor abordagem baseada nas técnicas em estudo.

1.1.2 Específicos

Para a análise das técnicas de pré-processamento com índices de branco e segmentação de lesões de vitiligo faz-se necessário a realização das seguintes etapas:

1. Criar uma base de imagens com lesões de vitiligo;
2. Explorar e realizar experimentos com técnicas de pré-processamento com índices de branco individualmente e suavização com o filtro da mediana, e técnicas de segmentação de Otsu e *k-means*;
3. Avaliar a segmentação das imagens através de métricas;
4. Propor uma abordagem para extração de lesões de vitiligo através das técnicas exploradas;
5. Comparar a abordagem proposta com algumas abordagens apresentadas na literatura.

1.2 CONTRIBUIÇÕES DO TRABALHO

O diagnóstico do vitiligo é essencialmente clínico, pois as manchas com pouca pigmentação aparecem geralmente em locais do corpo como boca, nariz e joelhos. Nesse contexto, o estudo das técnicas de pré-processamento e segmentação de imagens de vitiligo propostos neste trabalho contribuem para o avanço do desenvolvimento de ferramentas computacionais que auxiliem dermatologistas no processo de detecção da doença de vitiligo.

1.3 JUSTIFICATIVA

O vitiligo é uma doença que se caracteriza pelo aparecimento de manchas brancas provocadas pela despigmentação da pele (STEINER et al., 2004). Então, quanto mais rápido reconhecer a lesão melhor será o resultado do tratamento, podendo ser mais rápido e eficaz.

O uso de imagens digitais para diagnosticar doenças dermatológicas vem se destacando cada vez mais. Segundo Pereira e Rafael (1992), o processamento de imagens permite o tratamento e manipulação das imagens de acordo com os objetivos pretendidos.

Nesse contexto, esse trabalho pretende explorar técnicas de pré-processamento com índices de branco e segmentação para imagens de vitiligo. Segundo Beuren, Britto e Facon (2020), o uso dos índices de branco mostraram-se eficientes em uma abordagem de segmentação entre céu e chão. Dessa forma, aposta-se nos índices de branco pelo fato da lesão de vitiligo ter a coloração branca na imagem digital. Esses índices ainda não foram explorados na literatura para segmentação desse tipo de lesão.

1.4 DELIMITAÇÕES DO TRABALHO

Este estudo propõe uma abordagem de segmentação de lesões de vitiligo, a partir da análise das principais técnicas de pré-processamento com índices de branco e de segmentação, a partir de uma base criada para este fim. As técnicas de pré-processamento selecionadas serão testadas separadamente e em conjunto com as principais técnicas de segmentação de imagens.

2 REVISÃO DA LITERATURA

2.1 PROCESSAMENTO DE IMAGENS

O processamento digital de imagens representa um conjunto de técnicas para a extração e identificação de imagens, melhorando a qualidade visual de alguns aspectos estruturais (PEDRINI, 2012).

Ao decorrer dos anos, muitas tecnologias foram construídas na área de processamento de imagens, utilizadas em diferentes áreas de aplicação, como: astronomia, medicina, multimídia, entretenimento, robótica, aeronáutica, entre muitas outras (RUDEK; SANTOS; CANGIOLIERI, 2001).

Segundo Silva, Patrocínio e Schiabel (2019), processamento de imagens baseia-se em um conjunto de técnicas para facilitar a visualização da imagem ou adequá-la para análises quantitativas através de correções de defeitos ou realces das regiões de interesse nas imagens e a extração e tratamento de dados quantitativos, realizados pelo próprio computador.

Os sistemas do processamento de imagens geralmente compreendem uma arquitetura em etapas sequenciais e ordenadas como aquisição, pré-processamento, segmentação e pós-processamento. A Figura 2 mostra o fluxograma destas etapas.



Figura 2: Fluxograma das etapas do processamento de imagens.

Fonte:(ALBUQUERQUE; ESQUEF; ALBUQUERQUE, 2008).

2.1.1 Aquisições de imagens digitais

Este é o primeiro passo do processo, para adquirir a imagem digital, é necessário ter um dispositivo físico, ou seja, isto é que seja sensível a uma faixa do espectro eletromagnético que está apto a produzir um sinal elétrico adequado ao nível de energia, percebida e para converter a saída elétrica do dispositivo de sensoriamento para a forma digital é usado um digitalizador Gonzalez e Woods (2000) é coletar a energia de entrada e projetá-la em um plano imagem.




Figura 3: Aquisição de imagens.

Fonte:(REIS, 2014).

É usado o dispositivo de carga acoplada (“*charge-coupled devices*” – *CCDs*), ou seja, sensor que capta a imagem, formado por um circuito integrado que tem uma matriz de capacitores acoplados. Usados em fotografia digital entre outros dispositivos, é um sistema de digitalização interno para a geração de uma imagem digital, a qual pode ser transferida para um desktop (GONZALEZ; WOODS, 2000).

2.1.2 Pré-processamento

Essa etapa tem como objetivo aperfeiçoar a imagem o máximo possível, corrigindo defeitos do processo de aquisição da imagem, portanto, melhorando detalhes importantes para a análise. Vários passos de pré-processamento precisam ser execu-

tados para corrigir defeitos conhecidos e ajustar a intensidade da imagem de maneira satisfatória à visibilidade. Como, por exemplo, melhoras no brilho e no contraste, correção de iluminação irregular, realce de bordas e redução de ruídos Gomes (2009). As operações realizadas nesta etapa são chamadas de baixo nível, pois focam diretamente nos valores de intensidade dos pixels. Basicamente o pré-processamento é para melhorar a qualidade da imagem para as tarefas posteriores.

2.1.2.1 Suavização de imagens

Para que os ruídos contidos em imagens sejam reduzidos, usa-se uma técnica computacional para redução de ruídos Santos et al. (2020). No processamento digital de imagem, a técnica de suavização está dentro da etapa de pré-processamento de uma imagem.

Os filtros de suavização são divididos em lineares e não-lineares. Sucintamente, o linear aplica a suavização na imagem sem modificar o seu nível médio de cinza, já os filtros não-lineares não levam isso em consideração (GONZALEZ; WOODS, 2000).

Segundo o Sanches et al. (2015), os filtros lineares são bastante utilizados em diversas áreas, incluindo em processamento digital de imagens. São considerados filtros passa-baixo, que tem como a finalidade de borrar uma imagem para obter um efeito desfocado. Já os filtros não-lineares operam diretamente na matriz de pixels de uma imagem e suavizam os ruídos por meio da variância. Um exemplo de filtro de suavização não-linear é o filtro da mediana.

Segundo Jain, Kasturi e Schunck (1995), o filtro de mediana é considerado um dos melhores filtros para extrair ruídos. Na implementação é selecionado um pixel qualquer, que é definido como o pixel do cálculo no momento. A mediana é o valor do pixel selecionado de um conjunto aleatório, que é formado pelo próprio pixel escolhido e os pixels da sua vizinhança, organizados em ordem de grandeza caso a cardinalidade seja ímpar. Este filtro funciona em nível de cinza, mantendo o formato original das imagens e eliminando ruídos tendo pouca perda de nitidez. A figura 4

apresenta o efeito do filtro mediana.



Figura 4: Imagem original (a); Imagem processada com filtro de mediana (b).
Fonte:(PFLEGER, 2016).

2.1.2.2 Índices de Branco

Índices de branco medem o grau pertencente de branco. Esses índices são usados no clareamento de próteses dentárias, na indústria para análise de branquidão em materiais como plástico e papel e diversas aplicações em que a cor branca é relevante (BEUREN; BRITTO; FACON, 2020).

Os índices de branco encontrados nos estudos compreendem: ASTME, BERGER, CIE, GANZ, HARRISON, HUNTER LAB, LANIER, STENSBY, STEPHANSEN e TAUBE.

• W_{astme} (BEUREN; BRITTO; FACON, 2020): O índice de branquidão é calculado de acordo com a equação 2.1:

$$W_{Astme} = 3.388 * z - 3 * y \quad (2.1)$$

Com a conversão do espaço de cor RGB para o espaço de cor XYZ sendo apresentado na equação 2.2:

$$\begin{bmatrix} x \\ y \\ z \end{bmatrix} = \begin{bmatrix} 0.412453 & 0.357580 & 0.180423 \\ 0.212671 & 0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{bmatrix} \begin{bmatrix} r \\ g \\ b \end{bmatrix} \quad (2.2)$$

Tabela 1: Tabela de valores de a e b, coeficientes da equação 2.3.

	a	b
2º observador	3.440	3.895
10º observador	3.448	3.904

Fonte: Adaptado de (BEUREN; BRITTO; FACON, 2020).

• W_{Berger} (BEUREN; BRITTO; FACON, 2020) Conversão do espaço de cor RGB para o espaço de cor xyz. Em seguida, o índice de branquidão é calculado de acordo com a equação 2.3:

$$W_{Berger} = y + a * z - b * x \quad (2.3)$$

Com a e b sendo coeficientes do observador tabelados da seguinte forma.

• W_{Cie} (BEUREN; BRITTO; FACON, 2020): Conversão do espaço de cor RGB para o espaço de cor xyz. Em seguida, o índice de branquidão é calculado conforme a equação 2.4:

$$W_{Cie} = y + 800(x_0 - x) + 1700(y_0 - y) \quad (2.4)$$

Com x e y sendo coordenadas de cromaticidade normalizadas definidas de acordo com a equação 2.5 e 2.6:

$$x = \frac{x}{x + y + z} \quad (2.5)$$

$$y = \frac{y}{x + y + z} \quad (2.6)$$

x_0 e y_0 sendo as coordenadas de cromaticidade para a luminância do observador de origem, sendo os valores tabelados de acordo com a Tabela 2:

Tabela 2: Valores para x_0 e y_0 que são as coordenadas de cromaticidade da equação 5.

Value	C/2º	D50/2º	D65/2º	C/10º	D50/10º	D65/10º
x_0	0.3101	0.3457	0.3127	0.3104	0.3477	0.3138
y_0	0.3161	0.3585	0.3290	0.3191	0.3595	0.3310

Fonte: (BEUREN; BRITTO; FACON, 2020).

• W_{Ganz} (BEUREN; BRITTO; FACON, 2020): Conversão do espaço de cor RGB para o espaço de cor xyz. Em seguida, o índice de branquidão é calculado conforme equação 2.7:

$$W_{Ganz} = y + px + qy + c, \quad (2.7)$$

x, y, z: Valores encontrados a partir da conversão. Com x e y sendo coordenadas de cromaticidade normalizadas definidas a partir da equação 2.8 e 2.9:

$$x = \frac{x}{x + y + z}, \quad (2.8)$$

$$y = \frac{y}{x + y + z}, \quad (2.9)$$

e p, q, c sendo coeficientes nominais dados para a luminância D65/10, tabelados da seguinte maneira: $P = 1868,322$; $Q = 3695,690$; $C = 1809.441$.

• $W_{Harrison}$ (BEUREN; BRITTO; FACON, 2020): Com r e b sendo os componentes de vermelho e azul do pixel conforme a equação 2.10:

$$W_{Harrison} = 100 - (r - b) \quad (2.10)$$

• $W_{HunterLAB}$ (BEUREN; BRITTO; FACON, 2020): Aqui se utiliza a conversão do espaço de cor RGB para o espaço de cor espaço de cor xyz. Em seguida, o espaço de cor xyz é convertido para o espaço de cor $l^*a^*b^*$. O índice de branquidão é calculado conforme a equação 2.11:

$$W_{HunterLAB} = l - 3b \quad (2.11)$$

A conversão do espaço xyz para o espaço de cor $l^*a^*b^*$ é realizada de acordo com as equações 2.12, 2.13 e 2.14:

$$l = 100\sqrt{\frac{y}{W_n}} \quad (2.12)$$

$$a = 175\sqrt{\frac{0.0102 \cdot X_n}{y/y_n}} \left(\frac{x}{x_n} - \frac{y}{Y_n} \right) \quad (2.13)$$

$$b = 70 \sqrt{\frac{0.000847 \cdot z_n}{y/y_n} \left(\frac{x}{x_n} - \frac{z}{x_n} \right)} \quad (2.14)$$

Sob a luminância D65/10⁰ os valores de X_n , Y_n , Z_n são: $X_n = 0.95047$; $Y_n = 1.00000$; $Z_n = 1.08883$.

• W_{Lanier} (BEUREN; BRITTO; FACON, 2020): Utiliza a conversão do espaço de cor RGB para o espaço de cor xyz . Em seguida, o espaço de cor xyz é convertido para o espaço de cor $l^*a^*b^*$. O índice de branquidão é calculado como mostra a equação 2.15:

$$W_{Lanier} = 100 - \sqrt{(100 - l^*)^2 + a^{*2} + b^{*2}} \quad (2.15)$$

Com L^* , a^* , b^* , sendo definidos pela conversão mostrada nas equações 2.16, 2.17 e 2.18:

$$L^* = 116f(y/y_n) - 16 \quad (2.16)$$

$$a^* = 500f[(x/x_n) - f(y/y_n)] \quad (2.17)$$

$$b^* = 200[f(y/y_n) - f(z/z_n)] \quad (2.18)$$

Sob a luminância D65/10⁰, os valores de X_n , Y_n , Z_n são: $X_n = 0.95047$; $Y_n = 1.00000$; $Z_n = 1.08883$.

• $W_{Stensby}$ (BEUREN; BRITTO; FACON, 2020): Conversão do espaço de cor RGB para o espaço de cor xyz . Em seguida, o espaço de cor xyz é convertido para o espaço de cor $l^*a^*b^*$. O índice de branquidão é calculado como mostra a equação 2.19:

$$W_{Stensby} = l^* - 3b^* + 3a^* \quad (2.19)$$

• $W_{Stephansen}$ (BEUREN; BRITTO; FACON, 2020): Com r e b sendo os componentes de vermelho e azul do pixel de acordo com a equação 2.20.

$$W_{Stephansen} = 2b - r \quad (2.20)$$

• W_{Taube} (BEUREN; BRITTO; FACON, 2020): Com g e b sendo os componentes de verde e azul do pixel conforme a equação 2.22:

$$W_{Taube} = 4b - 3g \quad (2.21)$$

2.1.3 Segmentação

Esse processo basicamente divide uma imagem em suas unidades de interesse, ou seja, objetos ou regiões que a constituem. Portanto, a imagem segmentada é determinada por um conjunto de regiões que estão interligadas, mas não sobrepostas, sendo que cada pixel na imagem é relacionado exclusivamente a uma região (SILVA; PATROCÍNIO; SCHIABEL, 2019).

A segmentação é uma das principais etapas do processamento de imagens, geralmente de maior complexidade computacional. Considerando a descontinuidade e a semelhança dessas áreas, seu objetivo é separar as áreas relacionadas aos objetos representados na imagem. Segundo Guarda (2018) essa é uma etapa primordial para o processo de análises de imagens, já que é responsável por limitar as regiões que posteriormente serão classificadas por algoritmos de classificação. Portanto, a qualidade da segmentação tem influência direta no processo de análise de imagens.

Os algoritmos de segmentação de imagens baseiam-se nas categorias de descontinuidade e similaridade. A primeira está relacionada às mudanças repentinas dos níveis de cinza e usadas na detecção de bordas, detecção de linhas e de pontos isolados de uma imagem por meio de máscaras de convolução. Na similaridade, os algoritmos baseiam-se em limiarização, crescimento de regiões e aglomeração (RONCERO, 2005).

De acordo com Grando (2005), a limiarização é uma das técnicas mais comuns de segmentar e classificar imagens com base em pixels, a intensidade segue um ou mais limites. A subdivisão é de uma imagem de um histograma, onde os pixels são agrupados de acordo com sua intensidade, obtendo conformidade com um ou mais limites recomendados.

Gomes (2009) afirma que esses métodos são comumente usados, por exemplo, para analisar imagens de documentos para extrair caracteres, logotipos ou símbolos e imagens de doenças dermatológicas. A imagem obtida pela segmentação por limiar é binária o que divide a imagem em uma região pertencente ao fundo e uma região pertencente ao objeto. Existem muitas variações da limiarização, mas a maioria delas usa apenas as informações do histograma de cinza da imagem para realizar a limiarização. Atualmente o algoritmo Otsu é o mais usado na limiarização.

2.1.3.1 *K-means*

Na segmentação por clustering, um conjunto de dados são substituídos por grupos ou clusters. Basicamente os clusters são regiões contínuas deste espaço englobando uma alta densidade de pontos, separadas de outras regiões densas por regiões com baixa densidade de pontos. O algoritmo de agrupamento mais conhecido e comumente usado para a segmentação de lesões é o *k-means*.

k-means é um método usado para particionar automaticamente um conjunto de dados em k grupos, selecionando k centros de cluster iniciais e, em seguida, refinando-os iterativamente da seguinte forma (WAGSTAFF et al., 2001):

1. Cada instância d_x é atribuído ao seu cluster mais próximo do centro;
2. Cada centro de cluster C_i é atualizado para o meio de suas instâncias.

Portanto, os valores dos centroides são computados de forma iterativa, assim que há mudança no vetor de dados. Deste modo, a cada iteração, todos os subconjuntos de clusters C_i devem ser atualizados para achar um novo esquema de vetor de dados. No entanto, a convergência será alcançada quando não houver mais modificações no vetor de dados ou nos subconjuntos (FAGUNDES; BORGES; NETO, 2016). A

figura 5 mostra um exemplo do funcionamento do algoritmo *k-means*. Onde existe a convergência de (a) até em (e). Dois pontos foram escolhidos e os pontos que tem mais proximidade ao primeiro centro foram marcados em amarelo, os seguintes mais próximos foram marcados em azul. A partir de onde foram calculados os possíveis centroides destes grupos que estão em vermelho.

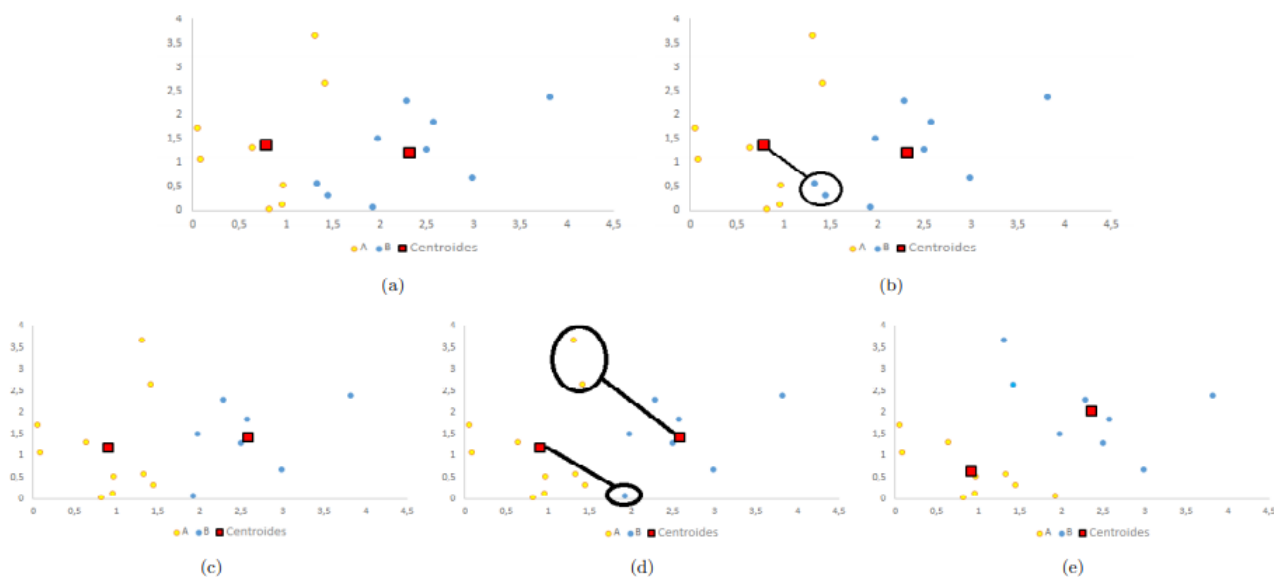


Figura 5: Iterações do *k-means*.
 Fonte: (FAGUNDES; BORGES; NETO, 2016).

2.2 MÉTRICAS DE AVALIAÇÃO

As métricas de avaliação são utilizadas para avaliar o desempenho de modelo que está sendo estudado. Portanto, as métricas geralmente são usadas para analisar o desempenho através de um agrupamento de dados específicos ou gerais (CHEN et al., 2020). As métricas mais comuns para avaliação da segmentação são: *Precision*, *Accuracy*, *Recall* e *F1-Score*.

2.2.1 Métrica *Precision*

De acordo com Cournapeau (2019), a *precision* avalia através de um conjunto de entradas de dados, números de verdadeiros positivos e de falsos positivos. Para calcular a precisão é necessário gerar a matriz de confusão que recebe as classes, por

exemplo, classes verdadeiras como P (positivo) e N (negativo), e as classes previstas como o S (sim) e N (não), como representado na figura 6.

	Positivo	Negativo
S	Positivos verdadeiros	Positivos falsos
N	Negativos falsos	Negativos verdadeiros

Figura 6: Exemplo de matriz de confusão.

Fonte: (NUNES, 2018).

De acordo com Cournapeau (2019), a *precision* (P) é definida como um número de verdadeiros positivos (TP) sobre o número de verdadeiros positivos mais o número de falsos positivos (FP). É calculado conforme a equação 2.22:

$$Precision = \frac{Tp}{Tp + Fp} \quad (2.22)$$

2.2.2 Métrica *Accuracy*

Segundo o Cournapeau (2019), *Accuracy* é considerada a métrica mais simples, basicamente esta métrica diz quantos dos exemplos foram segmentados corretamente. O cálculo é feito da seguinte forma: o número de acertos (positivos) dividido pelo número total de exemplos, que são a proporção entre os pontos segmentados, sendo as regiões de interesse, com a soma destes, e mais os pontos definidos como falsos positivos e falsos negativos. Portanto, é a divisão entre todos os acertos pelo total, calculado de acordo com a equação 2.23:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (2.23)$$

2.2.3 Métrica *Recall*

A métrica *Recall* faz o cálculo da proporção entre os exemplos corretos e o total de exemplos propostos (COURNAPEAU, 2019). Segue a equação da métrica *recall* (equação 2.24).

$$Recall = \frac{TP}{TP + FN} \quad (2.24)$$

2.2.4 Métrica *F1-Score*

A métrica *F1-Score* une as métricas *precision* e *recall* através da média harmônica, gerando resultados muito próximos da média “comum”. De modo que obtém-se um número único que indica a qualidade geral dos exemplos estudados (COURNAPEAU, 2019). Segue o cálculo da métrica *F1-Score* (equação 2.25).

$$F1 - Score = \frac{2 \cdot precision \cdot recall}{precision + recall} \quad (2.25)$$

2.3 ESTADO DA ARTE

Na abordagem de Simões (2000) uma técnica de segmentação de imagens fundamentada no atributo cor dos pixels foi criada com base em 45 imagens. A classificação é baseada em Redes Neurais Artificiais (RNAs), adotando a rede de perceptron multicamada. O treinamento foi realizado com cores contínuas, diferente saturações de cores, diferentes intensidades luminosas e três espaços de cores (RGB, YUV e HSV). O resultado dos treinamentos mostrou que em cores contínuas mostrou ser mais simples e eficaz.

Sezgin e Sankur (2004) realizaram um levantamento das técnicas de segmentação por limiarização. Os métodos são baseados em histogramas: *Rosenfeld*, *Guo*; Cluster: *Otsu* e *Yanni*; Entropia: *Kapur*, *Sahoo* e *Yen* e Similaridade de atributos: *Tsai* e *Pikaz*. O conjunto de dados consiste em 40 imagens de documentos. O resultado da qualidade média dos métodos foram: *Rosenfeld*: 0,663, *Guo*: 0,391; *Otsu*: 0,197 e *Yanni*: 0,323; *Kapur*: 0,149, *Sahoo*: 0,148 e *Yen*: 0,289; *Tsai*: 0,484 e *Pikaz*: 0,383. Os autores definem como melhores métodos para segmentar imagens de documentos *Rosenfeld*, *Yanni*, *Yen* e *Tsai*.

De acordo com Nugroho et al. (2007), o tratamento do vitiligo pode interrom-

per o crescimento da lesão e repigmentar as lesões cutâneas, porém, não tem uma resposta rápida durante o tratamento de determinar e quantificar a quantidade de repigmentação necessária. Os autores descrevem um esquema de processamento de imagens para identificar e determinar áreas da lesão e a progressão da repigmentação em tempo mais curto. As imagens de vitilgo foram coletadas de 4 pacientes. A análise foi realizada através do componente principal (PCA) e análise do componente independente (ICA) convertendo as imagens RGB em imagens que representa as áreas notoriamente das lesões cutâneas, e usando distância euclidiana para mapear cada pixel para facilitar a aplicação da técnica de segmentação por limiarização nas áreas afetadas. Comparando entre a Physician Global Assessment (PGA) e o método proposto no trabalho: para o primeiro paciente 66% no método proposto e 51%-75% a PGA; segundo paciente 94% e 76%-100% ao PGA; terceiro paciente 92% no método proposto e 76% - 100% a PGA; e o quarto paciente 26% no método proposto e 0-25% a PGA. Os autores concluem que o método é eficaz, sendo capaz de capturar pequenas progressões de repigmentação de forma clara e em menor tempo.

Soares (2008) apresentou uma metodologia para análise e classificação de imagens de doenças cutâneas, baseada em técnicas de processamento de imagens, utilizando descritores de textura, descritores de cor e descritores de forma. O processo de segmentação de imagens foi baseado no algoritmo de agrupamento *k-means* e, no pós-processamento aplicou operadores morfológicos para eliminar ruídos. Na classificação utilizou o SVM com objetivo de gerar hiperplanos viáveis que apresentam a maior margem de separação entre classes. Para a base 21 de imagens de doenças dermatológicas com melanoma e não-melanoma. Os resultados apresentam uma acurácia de 92,73% para melanoma e 86% para lesões não-melanoma.

Atualmente os dermatologistas utilizam as características da borda e de região interna das lesões compostas nas imagens para facilitar o diagnóstico da doença. Entretanto, Araujo et al. (2012) mostram uma metodologia híbrida para extrair e detectar os contornos das lesões de pele por meio de imagens. Usando uma base 40 imagens, aplicaram a remoção de ruídos nas imagens usando difusão anisotrópica, a técnica de segmentação por limiar, baseada em crescimento de região e algoritmos genéticos. Segundo os autores, em 92% dos casos, os contornos extraídos foram

considerados aceitáveis pela avaliação médica, por meio do método desenvolvido que uniu características das técnicas de segmentação para detectar, extrair e refinar as bordas das lesões.

Das et al. (2013) apresentam um método para identificação de doença cutâneas, criando uma base de 876 imagens composta por lesões como vitiligo, hanseníase e tineaversicolor. Para reconhecimento das lesões aplicaram o algoritmo Padrão Binário Local (LBP), Matriz de co-ocorrências de níveis de cinza (GLCM), *discrete cosine transform* (DCT) e Transformada de Fourier Discreta (TFD). Para a classificação das imagens utilizaram o SVM. Com base nos extratores de características, a precisão de cada um foi de DCT 73,56%, DFT 70,69%, GLCM 88,51 e LBP 88,51%. Com base nos resultados, os autores consideram o LBP o melhor extrator para as doenças vitiligo, hanseníase e tineaversicolor, e o classificador SVM teve uma precisão de reconhecimento de 89,66%, portanto, obteve resultado satisfatório.

Siebra (2013) apresentou um método de segmentação de imagens, baseado algoritmo *Multi Object Fuzzy Segmentation* (MOFS). O autor usou uma base de 13 imagens, aplicou a redução do histograma das imagens e, em seguida, a segmentação por crescimento de regiões e a segmentação por fuzzy. Os resultados alcançados através da métrica da Intersecção sobre União (IoU) foram satisfatórios, tendo uma média de 86,5253% de acurácia, mostrando eficaz em segmentar imagens textuais na presença de ruídos, obtendo um baixo desvio padrão de 1.9028.

Yasir, Rahman Md e Ahmed (2014) propuseram um método que utiliza técnicas de visão computacional para detectar vários tipos de doenças dermatológicas. Vários algoritmos de processamento de imagens são usados para a extração de características como a cor da área infectada, tamanho da área infectada em pixels e detecção de borda. As características extraídas de 775 imagens são usadas para treinar e testar uma rede neural artificial de propagação de *feedforward* para identificar a doença dermatológica. No pré-processamento, os autores aplicaram sequencialmente a conversão da imagem em níveis de cinza, filtro de nitidez, filtro da média, histograma, YCbCr para a extração da cor da imagem binária e o operador de sobel. E para segmentação foram implementado os métodos Otsu e Canny. Sistema detectou com

sucesso 9 tipos diferentes de doenças dermatológicas da pele, incluindo o vitiligo, com uma taxa de 90% de acurácia.

Adonias e Carlos (2015) apresentam uma avaliação de doenças cutâneas usando técnicas de segmentação e análise de imagens digitais. As imagens foram cedidas pelo Grupo de Visão Computacional e Cibernética da Universidade Independente de Bangladesh, contendo cinco imagens de lesões cutâneas e cinco imagens de vitiligo para comparação. A abordagem de segmentação consiste na detecção de bordas pelo método de Canny, limiarização pelo método de Otsu, segmentação pela técnica de Watershed e classificação pela média de intensidade dos pixels da região de interesse com limiar de 130 e pela matriz de coocorrência de níveis de cinza. A análise foi realizada entre manchas despigmentadas e manchas de intensidade mais escura na pele (pintas, sinais e etc.) através do cálculo da média de intensidade dos pixels. A média geral de intensidade dos pixels chegou a 197,03 para vitiligo e 93,97 para os demais sinais, taxa de acerto de 100% para as imagens testadas.

Marcomini, Schiabel e Vercosa (2015) propuseram na segmentação, a técnica de contorno ativo para obter informações precisas de nódulos de imagens clínicas para uma base de 83 imagens. Para a comparação correta as segmentações, os autores usaram métricas de avaliação quantitativa. Os resultados obtidos foram de 92% na acurácia, 73% em sensibilidade e 94% de valor preditivo positivo. O resultado da segmentação por contorno ativo foi satisfatório, sendo viável usá-la em imagens ultrassonográficas.

Yadav, Narang e Shrivastava (2016) apresentam um estudo abordando uma série de sistemas de diagnóstico de doenças de pele e plantas, por meio do processamento de imagens e mineração de dados. O estudo mostra uma implementação de um sistema de diagnóstico de doenças de pele que ajuda o usuário a detectar a doença de pele fornecendo tratamentos médicos em tempo hábil. O sistema necessita da imagem da doença de pele para que possa usar no pré-processamento, usando filtro de suavização e ruídos para o aprimoramento da imagem e a técnica de segmentação de limiarização. Este sistema especialista tem uma precisão de 85% para eczema, 95% para impetigo e 85% para melanoma.

Nosseir e Shawky (2019) desenvolveram um algoritmo para classificar três tipos de doenças cutâneas: verrugas, hemangioma e doenças de pele como vitiligo. Os autores usaram 240 imagens. O algoritmo proposto segue algumas etapas: baseada em características dos pixels, extração de características como cor e textura e matriz de co-ocorrência de nível de cinza (GLCM). E fizeram comparação da precisão dos classificadores supervisionados SVM e K-NN. O K-NN obteve resultados mais altos, apresentando uma precisão de 98,2% e o SVM de 90%.

Bian et al. (2020) propuseram um método fracamente supervisionado, usando a técnica de segmentação de vitiligo com apenas anotações em nível de imagem para localizar a lesão. A base contempla 2.000 imagens extraídas do Vit2019. Os autores usaram rede neural convolucional (CNN) para classificação das imagens e, em seguida, um mapa de ativação de classe (CAM) para localizar a região do vitiligo. A rede de classificação foi treinada com 70% das imagens de teste e 30% de imagens aleatórias.

Low e Raina (2020) apresentam uma rede neural convolucional (CNN) modificada com base na arquitetura da rede U-Net que realiza a segmentação de lesões cutâneas de vitiligo de forma rápida e robusta. Para o pré-processamento as imagens são normalizadas entre -1 a 1 para garantir a padronização da escala de pixels e redimensionadas para 224×224 . Um conjunto de 247 imagens foram combinadas para o treinamento e validação. Na avaliação do desempenho da rede, foi medido com f1-score chegando a 73,6%.

Luo et al. (2020) apresentam um sistema de inteligência artificial para diagnosticar vitiligo com capacidade de gerar imagens de alta resolução e classificá-las com precisão. A base foi composta por 80.000 imagens de vitiligo e imagens sem lesão. Para gerar estas imagens em *wood lamp*, os autores usaram *Cycle-Consistent Adversarial Networks* (Cycle Gan) e *Attention-Aware DenseNet(ARD)*, para melhorar a nitidez das imagens. Na classificação, os autores usaram a *Resnet50*. O desempenho do método na classificação foi de 85,69% de acurácia, um aumento de 9,32% em comparação com o uso do *Resnet50* para classificar imagens originais diretamente.

Beuren, Britto e Facon (2020) apresentaram uma abordagem de segmentação de

céu e chão utilizando o classificador supervisionado *Support Vector Machine* (SVM). Duas bases de dados de 1200 imagens foram criadas para executar os experimentos. A abordagem foi dividida em duas etapas, uma usando classificadores monolíticos e a segunda usando a fusão de classificadores. As duas etapas usaram índices de branco no pré-processamento e avaliadas com a métrica *F-measure*. Na primeira etapa os resultados variaram entre 89,10% e 92,80% para as bases e na segunda etapa que consiste na pré-classificação das imagens em categorias o melhor resultado atingiu 97,10% para uma base e 92,00% para a segunda base.

Tabela 3: Estado da arte

Artigo	Base de Dados	Tipo de imagens	Pré-processamento de imagens	Segmentação de imagens	Classificadores Algoritmos	Avaliação dos métodos	Resultados
SIMÕES, S. (2000).	Base de 45 imagens de cores.	Imagens coloridas.	-	Técnica de segmentação fundamentada no atributo da cor dos pixels	Redes neurais Artificiais (RNAs).	Os autores não citam as métricas de avaliação utilizadas.	O resultado dos treinamentos mostrou-se que em cores contínuas teve resultados simples e eficazes.
SEZGIN, M.; SANKUR, B. (2004).	Base de 40 imagens de documentos.	Imagens coloridas.	-	Segmentação por limiarização <i>Rosenfeld</i> , <i>Guo</i> , <i>Otsu</i> , <i>Yanni</i> , <i>Kapur</i> , <i>Sahoo</i> , <i>Yen</i> , <i>Tsai</i> , e <i>Pikaz</i> .	-	Os autores não citam as métricas de avaliação utilizadas.	Os resultados mostraram que os métodos <i>Rosenfeld</i> , <i>Yanni</i> , <i>Yen</i> e <i>Tsai</i> foram mais eficazes.

Tabela 3 Informações do Estado da Arte

Tabela 3 *Continuação da tabela do estado da arte*

NUGROHO, H. et al. (2007).	Base de 24 imagens de 4 pacientes com vitiligo.	Imagens coloridas.	<i>Principal component analysis</i> (PCA) e <i>component analysis</i> (ICA).	Segmentação por limiarização.	Classificação por distância euclidiana .	Os autores não citam as métricas de avaliação utilizadas.	O método foi capaz de capturar pequenas progressões de repigmentação de forma objetiva e se mostra potencialmente superior à avaliação médica.
SOARES, H. (2008).	Base de 21 imagens composta por doenças dermatológicas.	Imagens coloridas.	descritores de textura, descritores de cor e descritores de forma.	Segmentação feita através do algoritmo de <i>k-means</i> .	Classificador SVM.	Matriz de confusão	Os resultados foram positivos, obtendo uma acurácia de 92,73% para melanoma e 86% para lesões não-melanoma e benigna.
ARAUJO, A. et al. (2012).	Base de 40 imagens	Imagens coloridas	Remoção de ruído por difusão anisotrópica.	Segmentação por limiar, baseada em crescimento de região e algoritmos genéticos	-	Avaliação por um médico especialista.	92% dos casos, os contornos extraídos foram considerados aceitáveis pela avaliação médica.

Tabela 3 Informações do Estado da Arte

Tabela 3 *Continuação da tabela do estado da arte*

DAS, N. et al. (2013).	Base de 876 de imagens baseadas em doenças cutâneas.	Imagens coloridas.	Extratores de texturas: LBP, GLCM, DCT e TFD	-	Classificador SVM.	Métrica <i>Precision</i>	O extrator LBP teve uma maior precisão em comparação aos outros extratores e em conjunto com o classificador SVM teve 89,66% de precisão.
SIEBRA, A. (2013).	Base 13 de imagens.	Imagens coloridas.	Histograma das imagens.	Segmentação por regiões e segmentação por <i>Fuzzy</i> .	-	Métrica da Intersecção sobre União (IoU)	O método de Segmentação <i>Fuzzy</i> teve resultados satisfatórios, obtendo uma média de 87.5253% de acurácia e tendo um baixo desvio padrão de 1.9028.

Tabela 3 Informações do Estado da Arte

Tabela 3 *Continuação da tabela do estado da arte*

YASIR, R.; RAHMAN, M. A.; AHMED, N. (2014).	Base de 775 imagens de diferentes doenças dermatológicas	Imagens coloridas	Filtro de nitidez; filtro de média; Máscara binária; Histograma; Espaço de cores YCbCr; Filtro de sobel	-	Rede neural de retropropagação <i>feed-forward</i> com 10 características	O sistema examina uma imagem de pele infectada e detecta a doença com precisão	A taxa de acurácia foi de 90% para a abordagem proposta pelos autores.
ADONIAS, G.; REGIS, C.(2015).	Base de 5 imagens de vitiligo. e 5 imagens de lesões cutâneas diversas	Imagens coloridas.	Filtros da Mediana e Gaussiano	Método Canny; Algoritmo de Otsu; Técnica de <i>Watershed</i> .	Média de intensidade dos pixels da região de interesse; Matriz de coocorrência de níveis de cinza.	Cálculo geral da média da intensidade dos pixels.	O resultado mostrou-se eficaz para diferenciar manchas despigmentadas e doenças cutâneas com a média geral de intensidade de pixels de 197,03 das imagens de vitiligo e 93,97 de lesões cutâneas.

Tabela 3 Informações do Estado da Arte

Tabela 3 *Continuação da tabela do estado da arte*

MARCOMINI, K. et al. (2015).	Base de 83 imagens clínicas dermatológicas.	Imagens coloridas.	-	Segmentação por meio da técnica de contorno ativo.	-	Métricas: acurácia, sensibilidade e valor preditivo positivo (VPP).	A técnica utilizada obteve valores de 92% na acurácia, 73% em sensibilidade e 94% de valor preditivo positivo.
YADAV, N.; NARANG, K.; SHRI-VASTAVA, U. (2016).	Base de imagens de doenças eczema, impetigo e melanoma.	Imagens coloridas.	Filtros de suavização	Técnica de segmentação por limiarização	-	Criação de um sistema especialista.	O sistema proposto obteve uma precisão de 85% para Eczema, 95% para Impetigo e 85% para Melanoma.
Nosseir, A.; Shawky, M. (2019).	Base de 240 imagens.	Imagens coloridas.	-	Conversão da imagem em RGB.	<i>SVM</i> e <i>K-NN</i>	Acurácia.	<i>K-NN</i> obteve resultados mais altos, tendo uma precisão de 98,2% e o <i>SVM</i> 90% de acurácia.

Tabela 3 Informações do Estado da Arte

Tabela 3 *Continuação da tabela do estado da arte*

BIAN, Z. et al. (2020).	Base de 2.000 imagens de vitiligo	Imagens coloridas.	Mapa de ativação de classe (CAM).	Técnica de anotações em nível de imagem para localizar a lesão.	Redes neurais convolucionais (CNNs).	Métrica de Intersecção sobre União (IoU).	Os resultados obtidos tiveram maior pontuação em comparação aos algoritmos fracamente supervisionados.
Krizhevsky, Alex et al. (2020).	Base de 247 imagens de vitiligo.	Imagens coloridas.	Normalização entre -1 a 1 para a padronização da escala de pixel; redimensionamento para 224×224 .	CNN com base na arquitetura da rede U-Net	CNN e U-Net modificada	Métrica F-Measure.	Com o uso de U-Net obteve desempenho de 74,1%, mostrando-se promissor para a segmentação do vitiligo.
Luo, W. et al. (2020).	Base de 80.00 imagens contendo vitiligo e não contendo vitiligo.	Imagens coloridas	<i>Cycle-Consistent Adversarial Networks</i> (Cycle Gan); Attention-Aware DenseNet com Deconvolução Residual (ADRD).	-	Rede Neural Convocucional <i>Resnet50</i> .	Acurácia	Desempenho de 83,05%, aumento de 9,32% em comparação com o uso da Resnet50 diretamente em imagens originais.

Tabela 3 Informações do Estado da Arte

Tabela 3 *Continuação da tabela do estado da arte*

Beuren, A.; Britto, S.; Facon, J. (2020).	Duas bases de 1.200 imagens cada.	Imagens coloridas.	Índices de branco.	-	<i>SVM.</i>	Métrica F- Measure.	Os resultados variaram entre 89,10% e 92,80% na primeira etapa e 97,10% na segunda etapa.
--	---	-----------------------	-----------------------	---	-------------	------------------------	---

3 METODOLOGIA

A metodologia proposta tem como objetivo final extrair a lesão de vitiligo sem prejudicar a sua geometria avaliando técnicas de pré-processamento com índices de branco. O uso de índices de branco na etapa de pré-processamento justificam-se pelo fato do vitiligo apresentar a coloração branca em imagens digitais. Após o pré-processamento, algumas técnicas de segmentação serão aplicadas, para então serem avaliadas através das métricas *Precision*, *Accuracy*, *Recall* e *F1-Score*, mais comuns na literatura para esse tipo de abordagem. A figura 7 apresenta uma visão geral do protocolo a ser seguido ao longo dos experimentos.

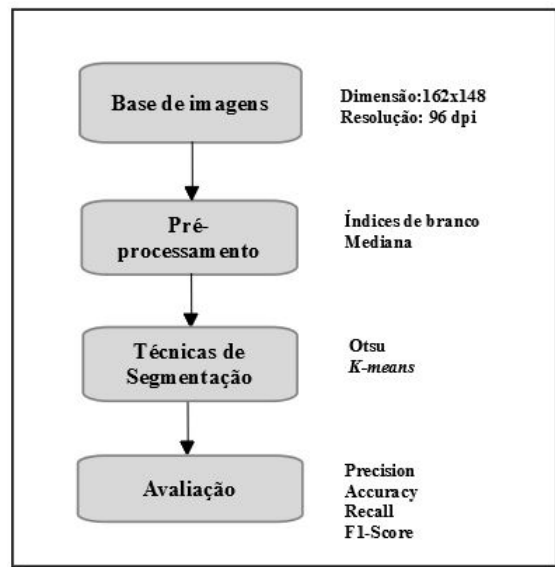


Figura 7: Protocolo dos experimentos.

Fonte: Autor.

As técnicas apresentadas no protocolo dos experimentos (figura 7) serão detalhadas nas próximas seções na forma de testes em diferentes implementações, usando como exemplo duas imagens de vitiligo. Na sequência do trabalho, estes testes serão realocados em uma seção específica no documento.

A seção 3.1 descreve a base de imagens criada para este trabalho. A seção 3.2 apresenta as técnicas de pré-processamento aplicadas, a seção 3.3 as técnicas de segmentação selecionadas. As métricas de avaliação definidas para o trabalho são apresentadas na seção 3.4.

3.1 BASE DE IMAGENS

Uma nova base foi criada a partir de imagens coletadas na web contemplando um total de 50. A criação da base justifica-se pela dificuldade em encontrar bases disponíveis e gratuitas para pesquisa. Inicialmente, as imagens tem diferentes tipos de resolução, tamanho e iluminação, fatores que afetam diretamente a extração da lesão. No intuito de padronizar a base de dados, todas as imagens foram ajustadas para o tamanho (162 x 148) e resolução de 96 dpi.

A formação da base *groundtruth* foi gerada manualmente a partir do contorno da lesão da imagem original. O termo “*groundtruth*” significa, neste contexto, gerar a solução ideal da segmentação da lesão da região do vitiligo para todas as imagens usadas nos experimentos.

A figura 8 apresenta exemplos de imagens que contemplam a base de dados e suas respectivas imagens *groundtruth*.




Figura 8: Imagens originais e respectivas *groundtruth*.

Fonte: Autor.

3.2 PRÉ-PROCESSAMENTO

A etapa de pré-processamento visa a normalização das das imagens de vitiligo, isto é, ajusta o brilho e reduz os ruídos. Nessa etapa, foram avaliados dez índices de branco: ASTME, BERGER, CIE, GANZ, HARRISON, HUNTER LAB, LANIER,

STENSBY, STEPHANSEN e TAUBE presentes Índices de Branco (seção 2.1.2.2). Após o processamento dos índices de branco, as imagens foram suavizadas com o filtro da mediana que é um filtro não-linear passa-baixas.

3.3 SEGMENTAÇÃO

A segmentação das imagens de vitiligo foi realizada com o método de Otsu e o algoritmo *k-means*, ambos aplicados a partir de imagens de cinza resultantes do pré-processamento.

Nessa etapa, o método de Otsu e o algoritmo *k-means* foram selecionados por apresentarem resultados eficientes em abordagens de imagens com diferentes tipos de lesões como citado no estado da arte, dos autores (SEZGIN; SANKUR, 2004) e (SOARES, 2008).

A segmentação com Otsu e *k-means* foi aplicada nas imagens resultantes dos índices de branco, imagens com índices mais filtro da mediana e nas imagens originais para comparação e comprovação da importância do pré-processamento, conforme figuras 9 e 10.

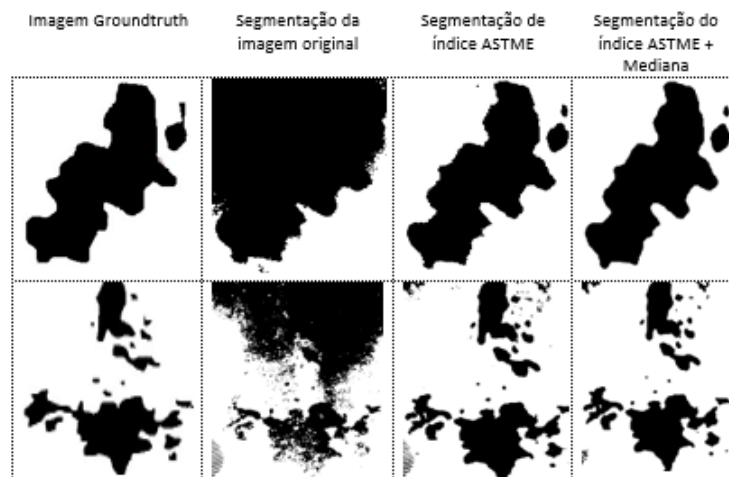


Figura 9: Segmentação com o método de Otsu.

Fonte: Autor.

Para a primeira imagem (linha 1), o melhor limiar encontrado é 157.0 e para a segunda imagem (linha 2) o limiar é 123.

O algoritmo *k-means* foi aplicado inicialmente com a configuração básica com a seleção de 2 classes e janela 3x3.

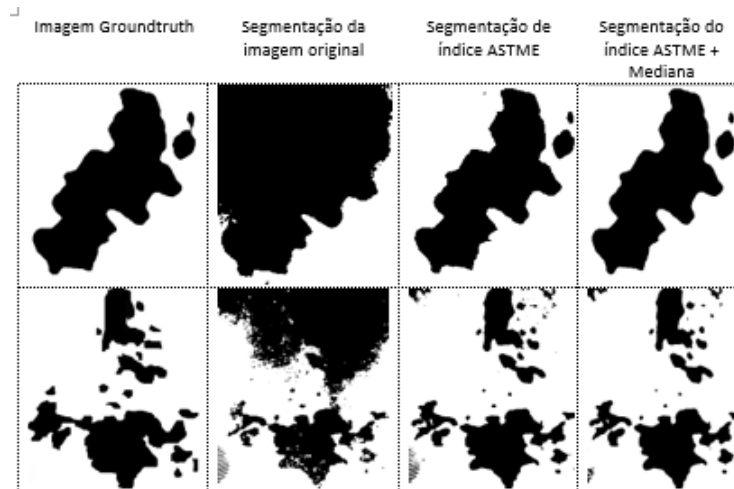


Figura 10: Segmentação com o algoritmo *k-means*.
Fonte: Autor.

3.4 AVALIAÇÃO DA ABORDAGEM PROPOSTA

Para avaliar os resultados obtidos, as métricas *Precision*, *Accuracy*, *Recall* e *F1-Score* foram escolhidas pelo fato de serem citadas na literatura para esse tipo de abordagem.

Essas métricas são calculadas a partir de quatro valores: Verdadeiro Positivo (TP) que indica a quantidade de pixels classificados como positivos corretamente; Verdadeiro Negativo (TN) indica a quantidade de pixels que foram classificados como negativos de maneira correta; Falso Positivo (FP) indica a quantidade de pixels que foram classificados como positivos de maneira incorreta e Falso Negativo (FN) que indica a quantidade de pixels que foram classificados como negativos de maneira incorreta.

Para essa abordagem, a métrica *Precision* retorna o percentual que realmente é considerado positivo a partir de todos os pixels classificados como positivos. A *Accuracy* é o indicador mais simples, calcula a divisão de todos os acertos pelo total. *Recall* indica o percentual de pixels classificados corretamente e que realmente são corretos. E, por fim, a métrica *F1-Score* que representa uma maneira de visualizar

as métricas *Precision* e *Recall* juntas.

As métricas *accuracy* e *f1-score* são usadas para indicar a performance geral da abordagem proposta já que a *f1-score* é uma junção da métrica *precision* e *recall*, e também vai ser avaliado pela métrica *accuracy*, por ser citada na literatura como uma das métricas mais utilizadas para este tipo de abordagem.

Com essas métricas é possível avaliar se as técnicas selecionadas nas etapas de pré-processamento e segmentação são viáveis ou não para o contexto de lesões de vitiligo.

4 ANÁLISE DOS RESULTADOS

Esta seção apresenta os resultados das técnicas aplicadas em três subseções: pré-processamento, segmentação e avaliação das métricas. Como citado na metodologia as métricas *accuracy* e *f1-score* foram usadas para avaliar a performance geral da abordagem proposta.

4.1 ANÁLISE DAS TÉCNICAS DE PRÉ-PROCESSAMENTO

Na etapa de pré-processamento as imagens de vitiligo foram padronizadas em relação ao tamanho e resolução. Nessa etapa, foram avaliados dez índices de branco: ASTME, BERGER, CIE, GANZ, HARRISON, HUNTER LAB, LANIER, STENSBY, STEPHANSEN e TAUBE, índices citados na seção 2.1.2.2. Nos resultados apresentados na figura 11 observa-se que, para alguns índices, houve um maior contraste entre a lesão e o fundo, como, por exemplo, os índices ASTME, BERGER e STEPHANSEN. Portanto, a aposta nos índices de branco se deu pelo fato das lesões de vitiligo apresentarem alto contraste da cor branca.




Figura 11: Resultados do pré-processamento dos índices de branco.

Fonte: Autor.

Após a aplicação dos índices de branco, ainda no pré-processamento, as imagens foram suavizadas com o filtro da mediana que é um filtro não-linear passa-baixas. O filtro da mediana consiste em substituir a intensidade de cada pixel pela mediana das intensidades na vizinhança do pixel, ou seja, os níveis de cinza dos pixels

que diferem significativamente de seus vizinhos (valores altos ou baixos), em uma dada vizinhança, serão descartados pelo filtro. Além disso, o filtro da mediana não introduz valores de níveis de cinza diferentes daqueles contidos na imagem original.

A escolha do filtro se deu por apresentar resultados expressivos nas imagens de vitiligo, como mostra a figura 12, imagens resultantes do pré-processamento com o índice ASTME e imagens suavizadas com o filtro da mediana. É possível observar que as imagens suavizadas com o filtro da mediana tiveram seus pixels levemente atenuados facilitando a segmentação da lesão na próxima etapa.




Figura 12: Resultados com o filtro de mediana.

Fonte: Autor.

4.2 ANÁLISE DAS TÉCNICAS DE SEGMENTAÇÃO

Na etapa da segmentação os algoritmos *k-means* e Otsu foram implementados em (python 3.8) em conjunto com as bibliotecas openCV (4.4.0.46), numpy (1.20.1), matplotlib (3.3.3) e scikit-learn (0.24.1).

O *k-means* foi dividido em dois clusters, atribuindo a cor branca ou preta para cada um deles. A figura 13 e mostra exemplos de imagens segmentadas pelo algoritmo *k-means*. Portanto, se a imagem original possuir uma boa resolução, o algoritmo reconhece de forma eficiente os clusters. Porém, como no exemplo da figura 14, onde a imagem original não obteve um contraste entre o fundo e a lesão,

pois o índice aplicado não a favoreceu, deixando implícito o que é a lesão e o que não é, o *k-means* não reconheceu de forma adequada.




Figura 13: Aplicação do algoritmo *k-means* + índice ASTME.
Fonte: Autor.




Figura 14: Aplicação do algoritmo *k-means* + índice LANIER.
Fonte: Autor.

A segmentação pelo método de Otsu tem como objetivo, a partir das imagens da lesão de vitiligo em tons de cinza, determinar o valor ideal de um threshold que separe os elementos do fundo e da lesão da imagem atribuindo a cor branca ou preta para cada um deles. A figura 15 mostra um exemplo do resultado da segmentação pelo o método Otsu e o o histograma da imagem não bimodal, tendo o melhor limiar como 104.0, ou seja, não teve a divisão clara da lesão e do fundo da imagem.




Figura 15: Resultado do método Otsu não bimodal.
Fonte: Autor.

Já a figura 16, apresenta uma imagem com histograma bimodal, com o melhor limiar de 145.0 levando a uma divisão clara entre a lesão e o fundo da imagem.




Figura 16: Resultado do método Otsu bimodal.

Fonte: Autor.

4.3 ANÁLISE DAS MÉTRICAS DE AVALIAÇÃO

Para avaliar os resultados das técnicas de pré-processamento e de segmentação foram utilizadas métricas de avaliação, *Precision*, *Accurray*, *Recall* e *F1-Score*, implementadas em python usando as bibliotecas *numpy* e *scikit-learn*. A tabela 4 e as figuras 20 e 21 mostram os resultados da segmentação das imagens com algoritmo Otsu e *k-means*, sem usar um pré-processamento.

Tabela 4: Avaliação da segmentação com *k-means* e Otsu.

Métricas de Avaliação	Otsu	<i>k-means</i>
Accuracy	77%	70%
Recall	76%	70%
Precision	87%	79%
F1-Score	79%	72%

Fonte: Autor.



Figura 17: Segmentação com algoritmo *k-means* na imagem original.

Fonte: Autor.




Figura 18: Segmentação com algoritmo de Otsu na imagem original.

Fonte: Autor.

É possível observar que os resultados das quatro métricas, tanto para o algoritmo Otsu e o K-means, não apresentaram valores expressivos. Nas figuras 17 e a 18, as segmentações tiveram dificuldade em distinguir o que era e o que não era a mancha, não reconhecendo os contornos das lesões. Com base nisto, sem um pré-processamento, a etapa da segmentação das imagens de vitiligo tem um resultado considerado baixo considerando a literatura.

Tabela 5: Avaliação dos índices de branco + Otsu.

Índice de branco	Otsu			
	Accuracy	Precision	F1-Score	Recall
ASTME	90%	89%	89%	87%
BERGER	90%	87%	87%	88%
CIE	79%	89%	89%	83%
GANZ	90%	82%	84%	77%
HARRISON	73%	78%	77%	77%
HUNTER-LAB	74%	89%	75%	70%
LANIER	65%	67%	66%	55%
STENSBY	80%	89%	88%	86%
STEPHANSEN	91%	86%	90%	93%
TAUBE	87%	88%	88%	86%

Fonte: Autor.




Figura 19: Segmentação com algoritmo de Otsu com índice de branco.

Fonte: Autor.

Pode-se observar que os resultados foram melhores com o pré-processamento. Considerando os dois melhores índices, ASTME e STEPHANSEN, a *accuracy* varia entre 90% e 91% e o *f1-score* entre 89% e 90%. Isso quer dizer, que esses índices apresentam um contraste melhor entre a mancha e o fundo.

A figura 19 mostra um exemplo da segmentação por Otsu para o índice ASTME em que o resultado não foi interessante. Para melhorar os resultados desse tipo de imagem que apresentam ruídos foi utilizado o filtro da mediana, de forma que mantém os detalhes de altas frequências como os contornos das imagens.

A tabela 6 apresenta os resultados dos índices de branco com filtro da mediana e Otsu.

Tabela 6: Avaliação dos índices de branco + mediana + Otsu.

Índice de branco	Filtro de Mediana + Otsu			
	Accuracy	Precision	F1-Score	Recall
ASTME	91%	92%	92%	90%
BERGER	92%	89%	92%	89%
CIE	91%	89%	90%	84%
GANZ	89%	84%	85%	78%
HARRISON	75%	79%	78%	79%
HUNTER-LAB	89%	76%	76%	71%
LANIER	68%	68%	70%	56%
STENSBY	89%	83%	89%	86%
STEPHANSEN	90%	90%	93%	92%
TAUBE	89%	89%	89%	87%

Fonte: Autor.




Figura 20: Segmentação com algoritmo de Otsu com índice + mediana.

Fonte: Autor.

Observa-se que a aplicação do filtro da mediana melhorou os resultados das métricas de *accuracy* e *f1-score* para os índices ASTME e STEPHANSEN e destacou o índice BERGER com 92% de *accuracy* e 92% de *F1-Score*.

A tabela 7 indica os resultados dos 10 índices de branco com o algoritmo *k-means*.

Tabela 7: Avaliação dos índices de branco + *k-means*.

Índice de branco	<i>k-means</i>			
	Accuracy	Precision	F1-Score	Recall
ASTME	90%	87%	91%	89%
BERGER	89%	89%	90%	88%
CIE	90%	81%	89%	81%
GANZ	89%	78%	81%	76%
HARRISON	73%	83%	76%	74%
HUNTER-LAB	81%	89%	82%	79%
LANIER	75%	80%	75%	73%
STEPNSBY	79%	89%	80%	77%
STEPHANSEN	91%	90%	92%	89%
TAUBE	87%	88%	88%	89%

Fonte: Autor.




Figura 21: Segmentação com índice + *k-means*.

Fonte: Autor.

A tabela 7 apresenta os índices ASTME e STEPHANSEN com *accuracy* entre 90% e 91% e *f1-Score* entre 91% e 92%. A figura 21, apresenta uma imagem com segmentação *k-means* com alguns ruídos, que serão minimizados com o filtro da mediana, conforme a tabela 8.

Tabela 8: Avaliação dos índices de branco + mediana + *k-means*

Índice de branco	Filtro de Mediana + <i>k-means</i>			
	Accuracy	Precision	F1-Score	Recall
ASTME	91%	90%	93%	90%
BERGER	90%	88%	91%	89%
CIE	91%	89%	91%	89%
GANZ	86%	89%	87%	84%
HARRISON	82%	84%	84%	86%
HUNTER-LAB	83%	91%	84%	81%
LANIER	77%	84%	78%	76%
STENSBY	82%	89%	83%	79%
STEPHANSEN	91%	90%	94%	89%
TAUBE	88%	89%	89%	89%

Fonte: Autor.



Figura 22: Segmentação com índice + mediana + *k-means*.

Fonte: Autor.

Os resultados com o filtro da mediana melhoraram a *accuracy* dos índices ASTME e STEPHANSEN para 91% e o *f1-score* para 93% e 94%, respectivamente. A figura 22 apresenta uma imagem com filtro da mediana e *k-means* e sua respectiva *groundtruth*.

5 COMPARAÇÃO DA ABORDAGEM PROPOSTA COM ABORDAGENS APRESENTADAS NA LITERATURA

Esta seção apresenta alguns estudos da literatura presentes no estado da arte (seção 2.3) em comparação com a abordagem proposta. Estudos em que o método de Otsu foi citado por autores foram comparados com os melhores índices de branco + mediana + Otsu apresentados na seção 4.3. Já os estudos que citam a segmentação com *k-means* foram comparados com os melhores índices de branco + mediana + *k-means* apresentados na seção 4.3. Nos dois casos, a métrica usada para comparação é a mesma, conforme a tabela 9.

Tabela 9: Comparação dos métodos.

Artigo	Método	Accuracy	F1-Score
(YADAV, et al.,2016)	Mediana+Canny+Otsu	90/%	-
(SOARES, 2008)	Textura+ <i>k-means</i>	92%	-
(KRIZHEVSKY, et al.,2012)	Rede neural convolucional	-	73%
Abordagem proposta	Índices de branco+Mediana+Otsu	90 a 92%	92 a 93%
Abordagem proposta	Índices de branco+Mediana+ <i>k-means</i>	91%	93 a 94%

Fonte: Autor.

6 CONCLUSÃO

Este trabalho teve como intuito analisar o desempenho de índices de branco na etapa de pré-processamento. Além desse índices, o filtro mediana foi aplicado auxiliando na remoção de ruídos nas imagens. Na etapa de segmentação os algoritmos de Otsu e *k-means* foram aplicados. As métricas usadas para a avaliação das técnicas são a *accuracy* e o *f1-score*.

Na segmentação com o algoritmo de Otsu, os índices ASTME, BERGER e STEPHANSEN apresentaram *accuracy* de 91%, 92% e 90%, e *f1-score* de 92%, 92% e 93%, respectivamente.

Para a segmentação com *k-means*, os melhores resultados de índices de branco foram ASTME e STEPHANSEN com *accuracy* de 91% e *f1-score* de 93% e 94%, respectivamente.

Com base nos resultados obtidos nos experimentos, o uso de índices de branco no pré-processamento de imagens de vitiligo são promissores com o algoritmo *k-means*.

A sugestão de trabalhos futuros é a aplicação de algoritmos de aprendizagem e redes neurais convolucionais (CNNs) para aumentar o desempenho dos índices de branco.

Referências

- ADONIAS, G.; CARLOS, R. Avaliação de Manchas de Pele Usando Processamento de Imagens. **Revista Principia - Divulgação Científica e Tecnológica do IFPB**, v. 1, n. 27, p. 111–117, 2015. Disponível em: <<https://periodicos.ifpb.edu.br/index.php/principia/article/view/535>>. Acesso em: 1 mai. 2021.
- ALBUQUERQUE, M.; ESQUEF, A.; ALBUQUERQUE, P. Image segmentation using nonextensive relative entropy. **IEEE Latin America Transactions**, v. 6, n. 5, p. 477–483, 2008. Disponível em: <<https://ieeexplore.ieee.org/document/4839118>>. Acesso em: 15 abr. 2021.
- ARAUJO, A. et al. Análise e caracterização de lesões de pele para auxílio ao diagnóstico médico. In: ARAUJO, A. et al. **Avanços em Visão Computacional**. Porto: Univesidade do Porto, 2012. cap. 1, p. 27–46.
- BALLARD, D. H.; BROWN, C. M. **Computer Vision**. 1. ed. Austin: Prentice Hall, 1982. 539 p.
- BEUREN, A.; BRITTO, S.; FACON, J. Segmentation Using Different Approaches. In: INTERNATIONAL JOINT CONFERENCE, 20006248., 2020, Glasgow. **2020 International Joint Conference on Neural Networks (IJCNN)**. Piscataway: IEEE, 2020. p. 1–8. Disponível em: <<https://ieeexplore.ieee.org/document/9206876>>. Acesso em: 10 mar. 2021.
- BIAN, Z. et al. REMOVED: VitSeg: Weakly supervised vitiligo segmentation in skin image. **Computerized Medical Imaging and Graphics**, v. 85, n. 101779, p. 101779, 2020. Disponível em: <<https://>

[//www.sciencedirect.com/science/article/pii/S0895611120300781](http://www.sciencedirect.com/science/article/pii/S0895611120300781)>. Acesso em: 1 mai. 2021.

BOTELHO, G. M. **Segmentação de imagens baseada em redes complexas e superpixels: uma aplicação ao censo de aves**. Set. 2014. 82 f. Tese (Doutorado em Ciências) – Universidade de São Paulo, São Carlos, 2014. Disponível em: <<https://teses.usp.br/teses/disponiveis/55/55134/tde-16032015-113613/pt-br.php>>. Acesso em: 1 mai. 2021.

CHEN, D. et al. **Métricas de Avaliação em Machine Learning: Classificação**. 2020. Disponível em: <<https://medium.com/kunumi/m%C3%A9tricas-de-avalia%C3%A7%C3%A3o-em-machine-learning-classifica%C3%A7%C3%A3o-49340dadb198>>. Acesso em: 19 fev. 2021.

COURNAPEAU, D. **Metrics and scoring: quantifying the quality of predictions**. 2019. Disponível em: <https://scikit-learn.org/stable/modules/model_evaluation.html>. Acesso em: 19 fev. 2021.

DAS, N. et al. An SVM based skin disease identification using local binary patterns. In: 2013 THIRD INTERNATIONAL CONFERENCE ON ADVANCES IN COMPUTING AND COMMUNICATIONS, 13991368., 2013, Cochín. **IEEE Computer Society**. Piscataway, 2013. p. 208–211. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/6686372>>. Acesso em: 5 mar. 2021.

FAGUNDES, F.; BORGES, C.; NETO, R. Aprendizado de Métrica Utilizando uma Função de Distância Parametrizada e o Algoritmo K-means. In: XIII ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL E COMPUTACIONAL, 2016. **Natural Computing**. Recife: Bracis, 2016. Disponível em: <<https://cin.ufpe.br/~bracis2016/>>. Acesso em: 10 out. 2020.

GOMES, F. **Visão computacional e segmentação de imagens por discriminação de textura**. Set. 2009. 120 f. Dissertação (Mestrado em Computação) – Universidade Federal de Pernambuco, São Carlos, 2009. Disponível

em: <<https://repositorio.ufpe.br/handle/123456789/2244>>. Acesso em: 1 mai. 2021.

GONZALEZ, R.; WOODS, R. **Processamento de Imagens Digitais**. 1. ed. Gainesville: Editora Blucher, 2000. 528 p.

GRANDO, N. **Segmentação de imagens tomográficas visando a construção de modelos médicos**. Ago. 2005. 113 f. Dissertação (Mestrado em Engenharia e Informática Industrial) – Universidade Tecnológica Federal do Parana, Curitiba, 2005. Disponível em: <http://www.dominiopublico.gov.br/pesquisa/DetalheObraForm.do?select_action=&co_obra=124841>. Acesso em: 1 mai. 2021.

GUARDA, S. Desenvolvimento de um método para integrar um segmentador de grandes imagens no banco de dados PostgreSQL, 2018.

JAIN, R.; KASTURI, R.; SCHUNCK, B. G. **Machine vision**. McGraw-hill New York, 1995. v. 5.

LOW, M.; RAINA, P. Automating Vitiligo Skin Lesion Segmentation Using Convolutional Neural Networks. In: 2020 IEEE 17TH INTERNATIONAL SYMPOSIUM ON BIOMEDICAL IMAGING (ISBI), 2020. **International Symposium on Biomedical Imaging (ISBI)**. USA, 2020. p. 1–4. Disponível em: <<https://ieeexplore.ieee.org/document/9098682>>. Acesso em: 11 out. 2020.

LUO, W. et al. An effective vitiligo intelligent classification system. **Journal of Ambient Intelligence and Humanized Computing**, Springer, p. 1–10, 2020.

MARCOMINI, K. D.; SCHIABEL, H.; VERCOSA, L. B. Aplicação de contornos ativos para a segmentação de nódulos em imagens de ultrassonografia da mama. **Revista Brasileira de Física Médica**, v. 6, n. 2, p. 103–107, nov. 2015. DOI: 10.29384/rbfm.2012.v6.n2.p103-107. Disponível em: <<https://rbfm.org.br/rbfm/article/view/196>>.

NOSSEIR, A.; SHAWKY, M. **Classificador automático para doenças de pele usando K-NN e SVM**. Nova York, EUA: Association for Computing Machinery, 2019. p. 259–262. Disponível em: <

org.ez48.periodicos.capes.gov.br/10.1145/3328833.3328862>. Acesso em: 11 set. 2020.

NUGROHO, H. et al. Determination of skin repigmentation progression. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 9910578., 2007. **2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. IEEE, 2007. p. 3442–3445. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/4353071>>. Acesso em: 12 ago. 2020.

NUNES, D.; ESSER, L. Vitiligo epidemiological profile and the association with thyroid disease. In: ANAIS BRASILEIROS DE DERMATOLOGIA, 2., 2011. **An. Bras. Dermatol.** Rio de Janeiro: SciELO Brasil, 2011. v. 86, p. 241–248.

NUNES, M. **Matriz de confusão, o que é? para que serve? onde vive?** 2018. Disponível em: <<https://www.linkedin.com/pulse/matriz-de-confus%C3%A3o-o-que-%C3%A9-para-serve-onde-vive-marcelo-nunes>>. Acesso em: 3 jul. 2020.

OAKLEY, A. **Vitiligo images**. 2015. Disponível em: <<https://www.dermnetnz.org/topics/vitiligo-images/?stage=Live>>. Acesso em: 20 abr. 2020.

PEDRINI, H. **Introdução ao processamento digital de imagem**. 2012. Disponível em: <https://www.ic.unicamp.br/~helio/disciplinas/MC919/aula_introducao.pdf>. Acesso em: 10 ago. 2020.

PEREIRA, A.; RAFAEL, J. Image processing in medicine. **Acta Médica Portuguesa**, v. 5, n. 1, p. 23–7, 1992. Disponível em: <<https://www.actamedicaportuguesa.com/revista/index.php/amp/article/view/3188>>. Acesso em: 10 set. 2020.

PFLEGER, S. G. **Redução de ruído em vídeos em tempo real baseado na fusão do filtro de Kalman e filtro bilateral**. 2016. 90 f. Dissertação (Mestrado em Computação) - Faculdade de Computação – Universidade Federal de Santa

Catarina, Florianópolis, 2016. Disponível em:

<<https://repositorio.ufsc.br/xmlui/handle/123456789/174438>>. Acesso em: 1 mai. 2019.

REIS, M. D. S. **Monitoramento Automático de Trânsito Através de Técnicas de Visão Computacional com o OpenCV**. 2014. 32 f. Dissertação (Mestrado em Computação) - Mestrado Profissional em Sistema de informação – Faculdade de Ciência Empresariais, 2014. Disponível em:

<<https://core.ac.uk/download/pdf/51455534.pdf>>. Acesso em: 1 mai. 2019.

RONCERO, V. G. **Um estudo de segmentação de imagens baseado em um método de computação evolucionária**. 2005. Tese (Doutorado) – UNIVERSIDADE FEDERAL DO RIO DE JANEIRO.

RUDEK, M.; SANTOS, L.; CANCEGLIERI, J. **Visão computacional aplicada a sistemas produtivos: fundamentos e estudo de caso**. Salvador, 2001. f. 1.

SANCHES, C. H. et al. Técnicas de Suavização de Imagens e Eliminação de Ruídos. **Anais do EATI–Encontro Anual de Tecnologia da Informação. Frederico Westphalen–RS**, p. 21–30, 2015.

SANTOS, F. et al. Detecção de Bordas e Suavização de Imagens Digitais via Métodos Variacionais. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 7, n. 1, 2020.

SBCD. **Sociedade Brasileira de Cirurgia Dermatológica: Vitiligo não é contagioso e tem tratamento**. 2020. Disponível em: <<https://www.sbcd.org.br/vitiligo-nao-e-contagioso-e-tem-tratamento/>>. Acesso em: 24 jul. 2020.

SEZGIN, M.; SANKUR, B. Survey over image thresholding techniques and quantitative performance evaluation. **Journal of Electronic imaging**, International Society for Optics e Photonics, v. 13, n. 1, p. 146–166, 2004.

SIEBRA, A. **Segmentação fuzzy de imagens coloridas com características texturais: uma aplicação a rochas sedimentares**. 2013. Diss. (Mestrado) – Universidade Federal do Rio Grande do Norte.

SILVA, A. M. M. da; PATROCÍNIO, A. C.; SCHIABEL, H. Processamento e Análise de Imagens Médicas. **Revista Brasileira de Física médica (Online)**, 2019.

SIMÕES, S. **Segmentação de imagens por classificação de cores: uma abordagem neural**. 2000. Tese (Doutorado) – Universidade de São Paulo.

SOARES, H. B. **Análise e classificação de imagens de lesões da pele por atributos de cor, forma e textura utilizando máquina de vetor de suporte**. 2008. Diss. (Mestrado). Disponível em:
<<https://repositorio.ufrn.br/jspui/handle/123456789/15118>>. Acesso em: 1 dez. 2020.

STEINER, D. et al. **Vitiligo**. 2004. f. 335–351. Tese (Doutorado) – Rio de Janeiro.

WAGSTAFF, K. et al. **Constrained k-means clustering with background knowledge**. 2001. f. 577–584. Tese (Doutorado).

YADAV, N.; NARANG, K.; SHRIVASTAVA, U. Skin diseases detection models using image processing: A survey. **International journal of computer applications**, Foundation of Computer Science, v. 137, n. 12, p. 34–39, 2016. Acesso em: 10 nov. 2020.

YASIR, R.; RAHMAN MD, A.; AHMED, N. Dermatological disease detection using image processing and artificial neural network. In: 8TH INTERNATIONAL CONFERENCE ON ELECTRICAL AND COMPUTER ENGINEERING, Dhaka. **International Conference on Electrical and Computer Engineering**. Piscataway, 2014. p. 687–690. Disponível em:
<<https://ieeexplore.ieee.org/abstract/document/7026918>>. Acesso em: 10 nov. 2020.