

Alex William Leal
Orientador: Prof. Dr. Antônio Oseas de Carvalho Filho

**Classificação automática de imagens de
texturas de pele em melanoma e não melanoma
utilizando índices de diversidade**

Picos - PI
Junho de 2021

Alex William Leal
Orientador: Prof. Dr. Antônio Oseas de Carvalho Filho

Classificação automática de imagens de texturas de pele em melanoma e não melanoma utilizando índices de diversidade

Monografia submetida ao Curso de Bacharelado em Sistemas de Informação como parte dos requisitos para obtenção do Grau de Bacharel em Sistemas de Informação.

Universidade Federal do Piauí
Campus Senador Helvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
Junho de 2021

FICHA CATALOGRÁFICA
Universidade Federal do Piauí
Campus Senador Helvídio Nunes de Barros
Biblioteca Setorial José Albano de Macêdo
Serviço de Processamento Técnico

L435c Leal, Alex William

Classificação automática de imagens de texturas de pele em melanoma e não melanoma utilizando índices de diversidade / Alex William Leal – 2021.

Texto digitado

Indexado no catálogo *online* da biblioteca José Albano de Macêdo-
CSHNB

Aberto a pesquisadores, com as restrições da biblioteca

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Piauí, Bacharelado em Sistemas de Informação, Picos-PI, 2021.

“Orientador: Dr. Antônio Oseas de Carvalho Filho”

1. Câncer-Pele. 2. Melanoma. 3. Descritores de Textura. 4. Índices de Diversidade. I. Carvalho Filho, Antônio Oseas de. II. Título

CDD 004


CLASSIFICAÇÃO AUTOMÁTICA DE TEXTURAS DE IMAGENS DE PELE EM MELANOMA E NÃO
MELANOMA UTILIZANDO ÍNDICES DE DIVERSIDADE


ALEX WILLIAM LEAL


Monografia APROVADA como exigência parcial para obtenção do grau de Bacharel em
Sistemas de Informação.

Data de Aprovação

Picos – PI, 28 de JUNHO de 2021


Prof. Antônio Oseas de Carvalho Filho


Prof. Nonato Rodrigues de Sales Carvalho


Prof. José Anatiel Gonçalves Santos Landim

Agradecimentos

Primeiramente a Deus, por me proporcionar saúde e perseverança para concluir esse trabalho.

À minha mãe Uilma Maria Leal, pelo apoio incondicional, paciência e aconselhamentos nos momentos de dificuldade e desânimo.

Ao meu Prof. Dr. Antônio Oseas de Carvalho Filho por entender minhas dificuldades, sempre ser prestativo e paciente em sanar minhas dúvidas, além de me proporcionar crescimento acadêmico, durante o desenvolvimento deste trabalho.

Ao meu primo Henrique Laronso e meu irmão Wildyson Dantas por toda a paciência e ajuda com trabalhos durante o curso.

À Carolina Maria por estar sempre ao meu lado, me ouvindo e me apoiando incondicionalmente.

À minha amiga e irmã Thais Raiane, por todo o apoio.

À todos os meus amigos do curso pela parceria construída.

E por fim, a todos que, de forma direta ou indireta, contribuíram para à realização deste sonho.

*O sonho é o que leva a gente para a frente. Se a gente for seguir a razão, fica aquietado,
acomodado.*

Ariano Suassuna

Resumo

O câncer de pele é definido pelo crescimento anormal e descontrolado das células que compõem a pele. Entre os cânceres de pele, o menos frequente é o melanoma, porém possui o pior prognóstico, sendo o mais letal e correspondendo a 3% dos 30% de cânceres de pele no Brasil. Apesar de ser o mais nocivo, se houver uma detecção precoce as chances de cura são de 95%. O método aplicado para o diagnóstico precoce do melanoma é o exame dermatológico. O presente estudo apresenta um método de classificação de lesões na pele em melanoma e não melanoma por meio de imagens. Na primeira etapa, é feita a aquisição das imagens oriundas da base PH2. Na segunda, o pré-processamento, através de técnicas de processamento de imagem. Na terceira etapa, a extração de características, através dos índices de diversidade. E na quarta etapa, é a classificação em melanoma ou não, onde foram utilizados os classificadores *Random Forest*, *Sequential Minimal Optimization (SMO)*, *Multilayer Perceptron (MLP)* e *Instance Based Learning (IBK)*. Portanto, o processo é finalizado com a validação dos resultados. Neste método foram usados descritores de textura baseado em índices de diversidade para extração de características. A metodologia proposta alcançou uma acurácia de 90,5%, sensibilidade de 97,5%, especificidade de 62,5%, curva ROC de 0,800 e uma *Kappa* de 0,669. O uso dos índice de diversidade para descrever padrões em regiões de imagens de mamografias mostrou-se eficiente na categorização de melanoma e não melanoma. O mesmo contribuiu de forma positiva em duas distintas áreas. Sendo que na área da saúde, disponibilizou uma metodologia automática para auxílio no diagnóstico de lesões na pele em melanoma e não melanoma, que apesar de não fornecer excelentes resultados mostra-se promissor. E na computação, com a adaptação de técnicas de outras áreas do conhecimento que serviram como descritores de textura, permitindo então, que sejam utilizados para caracterizações em outros tipos de imagens.

Palavras-chaves: Câncer de Pele, Melanoma, Descritores de Textura, Índices de Diversidade.

Abstract

Skin cancer is defined by the abnormal and uncontrolled growth of the cells that make up the skin. Among skin cancers, melanoma is the least frequent, but it has the worst prognosis, being the most lethal and corresponding to 3% of the 30% of skin cancers in Brazil. Despite being the most harmful, if there is early detection the chances of cure are 95%. The method applied for the early diagnosis of melanoma is the dermatological examination. The present study presents a method of classification of skin lesions into melanoma and non-melanoma using images. In the first step, images from the PH2 base are acquired. In the second, the pre-processing, through image processing techniques. In the third step, the extraction of characteristics, through the diversity indices. And the fourth step is the classification into melanoma or not, where the classifiers *Random Forest*, *Sequential Minimal Optimization (SMO)*, *Multilayer Perceptron (MLP)* and *Instance were used Based Learning (IBK)*. Therefore, the process ends with the validation of the results. In this method, texture descriptors based on diversity indices were used for feature extraction. The proposed methodology achieved an accuracy of 90.5%, a sensitivity of 97.5%, a specificity of 62.5%, a ROC curve of 0.800 and a *Kappa* of 0.669. The use of diversity indexes to describe patterns in regions of mammogram images proved to be efficient in categorizing melanoma and non-melanoma. It contributed positively in two different areas. In the health area, it provided an automatic methodology to aid in the diagnosis of skin lesions in melanoma and non-melanoma, which, despite not providing excellent results, shows promise. And in computing, with the adaptation of techniques from other areas of knowledge that served as texture descriptors, allowing them to be used for characterizations in other types of images.

Keywords: Skin Cancer, Melanoma, Texture Descriptors, Diversity Indices.

Lista de ilustrações

Figura 1 – Imagem de mancha na pele do tipo melanoma.	14
Figura 2 – Etapas de um sistema PDI (ROCHA et al., 2014).	15
Figura 3 – Metodologia proposta.	25
Figura 4 – Exemplos de imagens contidas na base PH2.	26
Figura 5 – (a) Imagem Original e (b) Imagem Equalizada.	26
Figura 6 – Histograma da Imagem Original e da Imagem Equalizada.	27
Figura 7 – (a) Imagem Original e (b) Imagem Realçada.	27
Figura 8 – Histograma da Imagem Original e da Imagem Realçada.	27
Figura 9 – Quantizações aplicadas na metodologia.	28

Lista de tabelas

Tabela 1 – Índice de Diversidade	17
Tabela 2 – Matriz de confusão	21
Tabela 3 – Tabela de Concordância do Coeficiente Kappa.	21
Tabela 4 – Resultado dos testes utilizando imagens sem nenhum melhoramento de contraste.	30
Tabela 5 – Resultado dos testes utilizando imagens realçadas com Equalização do Histograma.	31
Tabela 6 – Resultado dos testes utilizando imagens realçadas com CLAHE.	32
Tabela 7 – Comparativo com os Trabalhos Relacionados.	32

Lista de abreviaturas e siglas

A	Acurácia
AUC	Área sob curva ROC
CAD	<i>Computer-Aided Detection</i>
CADx	<i>Computer-Aided Diagnostic</i>
CLAHE	<i>Contrast Limited Adaptive Histogram Equalization</i>
E	Especificidade
FN	Falso Negativo
FP	Falso Positivo
IBK	<i>Instance Based Learning</i>
K	Coefficiente <i>Kappa</i>
MLP	<i>Multi Layer Perceptron</i>
PDI	<i>Digital Image Processing</i>
ROC	<i>Receiver Operation Characteristic</i>
ROI	<i>Region of Interest</i>
S	Sensibilidade
SMO	<i>Sequential Minimal Optimization</i>
SVM	<i>Support Vector Machine</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
WEKA	<i>Waikato Environment for Knowledge Analysis</i>

Lista de símbolos

H'	Índice de Shannon
S	Total de espécies da amostra
i	Espécie
n_i	Número de indivíduos
N	Total de indivíduos
\ln	Logaritmo
D	Índice de Simpson
D	Índice de Margalef
D	Índice de McIntosh
U	Distancia Euclidiana
p_i	Proporção de indivíduos da especie i
p_j	Proporção de indivíduos da especie j
π	Pi
Σ	Somatório

Sumário

1	Introdução	11
1.1	Objetivos	12
1.2	Organização do Trabalho	12
2	Referencial Teórico	13
2.1	Melanoma	13
2.2	Sistemas Computacionais de Auxílio à Detecção e Diagnóstico	14
2.3	Processamento Digital de Imagens	14
2.4	Pré-processamento	15
2.4.1	Equalização do histograma	16
2.4.2	<i>Contrast-limited Adaptive Histogram Equalization (CLAHE)</i>	16
2.4.3	Quantização	16
2.5	Índices de diversidade	17
2.5.1	Índice de Shannon	17
2.5.2	Índice de Simpson	18
2.5.3	Índice de Margalef	18
2.5.4	Índice de McIntosh	18
2.6	Reconhecimento de Padrões	19
2.7	Métricas de Validação	20
3	Trabalhos Relacionados	23
4	Metodologia	25
4.1	Aquisição das Imagens	25
4.2	Pré-Processamento	26
4.3	Extração de Características	28
4.4	Classificação e Validação dos Resultados	28
5	Resultados e Discussões	30
5.0.1	Discussões	33
6	Conclusão	34
	Referências	35

1 Introdução

O câncer de pele é uma doença que é provocada pelo crescimento anormal e descontrolado das células que compõem a pele. Essas células se dispõem formando camadas e, de acordo com as que forem afetadas, são definidos os diferentes tipos de câncer. Os mais comuns são os carcinomas basocelulares e os espinocelulares. O câncer de pele mais agressivo é conhecido como melanoma, sendo o mais raro e nocivo entre os outros tipos de cânceres de pele (INCA, 2020).

Quanto maior for a exposição solar, mais elevado é o risco de tumores pré-cancerosos e cânceres de pele, incluindo o melanoma (BENEDETTI, 2019).

O câncer de pele responde por 30% de todos os diagnósticos desta doença no Brasil, sendo que o Instituto Nacional do Câncer (INCA) registra, a cada ano, cerca de 180 mil novos casos (INCA, 2020). Entre os cânceres da pele, o melanoma é o menos frequente, porém o mais letal. Segundo o INCA (2020), no Brasil, embora o câncer de pele seja o mais frequente tendo 30% de todos os tumores malignos registrados, apenas 3% são do tipo melanoma, com 8.450 novos casos diagnosticados com essa doença no ano de 2020. As mulheres são maioria nos números de casos, com um total de 4.250 casos e os homens com 4.200. O número de mortes são de 1.978, sendo 1.159 homens e 819 mulheres.

Com o uso de exames dermatológicos, a incidência de câncer de pele pode ser tratada de forma precoce, o que aumenta a chance de cura do paciente, porém, alguns fatores podem comprometer os prognósticos, como a inexperiência do especialista, a qualidade do exame, diagnósticos de doenças parecidas na pele, acarretando em possíveis erros na detecção da doença (INCA, 2020).

No diagnóstico dermatológico, as lesões são examinadas clinicamente, utilizando primeiramente a técnica de análise das características e textura, para então diagnosticá-las e tratá-las. Para facilitar este processo, os dermatologistas podem dispor de sistemas computacionais, que analisam as características das lesões de forma mais precisa, utilizando imagens digitais, para auxiliar no seu diagnóstico (OLIVEIRA, 2012).

A área de processamento e análise digital de imagens é um dos campos mais importantes da ciência médica devido ao rápido e contínuo progresso na visualização de imagens médicas e avanços nos métodos de diagnóstico assistido por computador e terapias guiadas por imagens. Essa área vem sendo essencial para a detecção precoce, o diagnóstico e a avaliação da resposta ao tratamento do câncer (SILVA; PATROCÍNIO; SCHIABEL, 2019).

De acordo com Guaragnella e Rizzi (2020), os sistemas de diagnóstico auxiliados por computador (*computer-aided diagnosis, CADx*) tem como objetivo aumentar o desempenho clínico, auxiliando na identificação e localização precoce de potenciais anormalidades. Portanto, o sistema CADx opera como uma segunda opinião automatizada ou como um

sistema de dupla leitura que auxilia os dermatologistas na avaliação precoce do câncer de pele e no acompanhamento de lesões cutâneas pigmentadas.

O trabalho desenvolveu um método capaz de integrar um sistema CADx atuando no diagnóstico automático do melanoma, categorizando em melanoma ou não. Para isso, são extraídas as características das imagens baseadas em textura utilizando índices de diversidade. Por fim, é feito o reconhecimento de padrões com múltiplos classificadores para avaliar a relevância da pesquisa proposta, com base nos resultados obtidos em cada classificador e determinar se o trabalho proposto é relevante para que os especialistas tenham uma segunda opinião no diagnóstico da doença.

1.1 Objetivos

Desenvolver uma abordagem para a classificação de regiões em melanoma e não melanoma, utilizando índices de diversidade.

Os objetivos específicos são:

1. Desenvolver e adaptar técnicas para caracterizar propriedades de textura;
2. Classificar as regiões de interesse em melanoma e não melanoma.
3. Analisar a usabilidade do uso de índices de diversidade como forma de extração de características; e
4. Construir uma metodologia para que os especialistas tenham uma segunda opinião no diagnóstico do melanoma.

1.2 Organização do Trabalho

Além da Introdução, este trabalho está organizado na seguinte ordem: O Capítulo 2 descreve todo o embasamento teórico para o entendimento da metodologia utilizada no trabalho; No Capítulo 3, são mostrados os principais trabalhos relacionados; No Capítulo 4, é abordado todo o desenvolvimento da pesquisa, tendo como início a aquisição das imagens, extração de características, classificação e por último a validação da metodologia proposta; No Capítulo 5, detalha os resultados obtidos com a metodologia proposta; e Por fim, é apresentado a conclusão do trabalho proposto no Capítulo 6.

2 Referencial Teórico

Para melhor entendimento deste trabalho, faz-se necessário a descrição de conceitos relacionados ao tema. Este capítulo aborda todo o embasamento teórico utilizado na metodologia proposta para facilitar sua compreensão. Diante disto, serão abordados os seguintes tópicos: Melanoma, Sistemas CADx, Processamento digital de imagens, Pré-processamento, Índices de diversidade, Reconhecimento de padrões e Métricas de validação.

2.1 Melanoma

O melanoma é o câncer originado a partir do crescimento desordenado dos melanócitos. Os melanócitos são as células que produzem o pigmento principal na produção de cor da pele, a melanina. Na maioria dos casos, a exposição excessiva à radiação ultravioleta é a causadora dos danos ao DNA dos melanócitos. Um dos tumores mais perigosos, o melanoma tem a capacidade de invadir qualquer órgão, criando metástases, inclusive cérebro e coração. Portanto, é um câncer com grande letalidade (UTIYAMA et al., 2019).

O diagnóstico precoce do melanoma é fundamental. Embora apresente pior prognóstico, avanços na medicina e o recente entendimento das mutações genéticas, que levam ao desenvolvimento dos melanomas, possibilitaram que pessoas com melanoma avançado hoje tenham aumento na sobrevida e na qualidade de vida (GUERRA et al., 2019).

Quando o médico percebe sinais de melanoma, o mesmo analisa o histórico clínico completo do paciente, observando os sintomas e fatores de risco. Para diagnosticar o melanoma e determinar o grau de comprometimento da doença, sendo solicitado a realização de alguns exames.

Durante o exame físico, o médico observará o tamanho, forma, cor e textura das lesões em questão, e se há sangramento ou descamação. Junto com o exame físico, alguns especialistas usam dermatoscopia para avaliar as manchas na pele com mais precisão. O médico utiliza um cromatoscópio, uma lente de aumento especial com fonte de luz própria para observar a pele. Às vezes uma fina camada de álcool ou óleo é usada com esse instrumento. Uma imagem digital ou fotográfica pode ser feita do local (AMERICAN CANCER SOCIETY, 2019). A Figura 1 mostra uma imagem do tipo melanoma.



Figura 1 – Imagem de mancha na pele do tipo melanoma.

2.2 Sistemas Computacionais de Auxílio à Detecção e Diagnóstico

A computação na área da saúde estuda e desenvolve sistemas computacionais para apoio às atividades médicas, trabalhando com análise e processamento digital de sinais bioelétricos, processamento digital de imagens médicas, desenvolvimento de sistemas de monitoração, apoio ao diagnóstico e à decisão e sistemas de instrução inteligente auxiliada por computador.

Diagnóstico auxiliado por computador (CADx) pode ser definido como um diagnóstico utilizando os resultados de análises quantitativas automatizadas de imagens digitais, auxiliando os profissionais na tomada de decisões para o diagnóstico. (AZEVEDO-MARQUES, 2001).

A detecção de anomalias em imagens médicas, em geral é um procedimento demorado, propício a erros e a algum grau de subjetividade devido a várias razões.

CADx alerta o profissional a examinar detalhadamente padrões suspeitos detectados pelo sistema. Isto melhora a acurácia do diagnóstico e a consistência da interpretação da imagem, servindo como uma “segunda opinião” quanto à tomada de decisões diagnósticas (PIRES et al., 2006).

2.3 Processamento Digital de Imagens

O processamento Digital de Imagens (PDI) Trata-se de um conjunto de técnicas para a análise de dados multidimensionais, que permitem manipular e tratar imagens com objetivo de obter informações e melhorar as características visuais da imagem. Porém, não é uma tarefa simples de ser realizada, pois ela envolve um conjunto de etapas interligadas (PEREIRA, 2018). A seguir, apresenta-se as etapas do processamento digital de imagens.

Uma imagem pode ser definida como uma função bidimensional, $f(x,y)$, em que x e y são coordenadas espaciais (plano), e a amplitude de f em qualquer par de coordenadas (x,y) é chamada de intensidade ou nível de cinza da imagem nesse ponto. Quando x , y e os valores de intensidade de f são quantidades finitas e discretas, denomina-se de imagem digital (JÚNIOR; SOARES, 2019).

Para ROCHA et al. (2014) os passos fundamentais de processamento digital de imagens podem ser divididos em cinco etapas conforme mostrado na Figura 2.




Figura 2 – Etapas de um sistema PDI (ROCHA et al., 2014).

A primeira etapa é a Aquisição de Imagens, que consiste em capturar as imagens necessárias, por meio de dispositivos móveis ou digitalização via *pixels*, para que sejam interpretadas pelas próximas etapas.

A segunda etapa é o Pré-processamento. Nesta etapa a imagem passa por um processo de filtragem, no qual são eliminados os ruídos, que podem ser obtidos durante a captura da imagem, melhorando assim a qualidade e permitindo uma melhor discriminação dos objetos presentes na mesma.

A terceira etapa é a Segmentação. Esta etapa tem por objetivo separar a imagem como um todo nas partes que a constituem e que se diferenciam entre si. É usual denominar “objetos” da imagem os grupos de *pixels* de interesse, ou que fornecem alguma informação para o PDI. Da mesma forma, a denominação “fundo” da imagem é utilizada para o grupo de *pixels* que podem ser desprezados ou que não têm utilidade no PDI. É nesta etapa que são definidas as regiões de interesse para processamento e análise posteriores.

A quarta etapa é Representação e Descrição. Nesse momento se extrai as informações úteis da imagem processada. Quando o objetivo do processamento é obter informações numéricas, realiza-se a extração de atributos da imagem.

Por fim, a quinta e última etapa é a Classificação e Reconhecimento, tem por objetivo, de forma automática, “rotular” os objetos segmentados da imagem com base nos seus descritores através de uma base de conhecimento que foi construída na etapa anterior.

2.4 Pré-processamento

O pré-processamento consiste na utilização de mecanismos de processamento de imagens para o realce das mesmas. Dentre os mecanismos, para que haja maior nitidez nas características da imagem, podemos citar o aumento de contraste e a retirada de possíveis ruídos. Na metodologia proposta utilizou-se de técnicas visando o melhoramento do contraste das imagens, sendo elas, Equalização do histograma, *Contrast-limited Adaptive Histogram Equalization* (CLAHE) e Quantização.

2.4.1 Equalização do histograma

Este realce consiste numa maneira de manipulação de histograma reduzindo automaticamente o contraste em áreas muito claras ou muito escuras, expandindo também os níveis de cinza ao longo de todo intervalo. É uma transformação não-linear que considera a distribuição acumulativa da imagem original, para gerar uma imagem resultante, cujo histograma será aproximadamente uniforme (LEITE; ROSA, 2012).

De acordo com Jantsch e Felipussi (2013) forma mais usual de se equalizar um histograma é pelo emprego da função de distribuição acumulada da distribuição de probabilidades original, expressa pela equação 2.1,

$$S_k = \sum_{j=0}^k p_r(r_j) \quad (2.1)$$

onde $0 \leq r_k \leq 1$ representando da intensidade do nível de cinza; $k = 0, 1, \dots, L - 1$ com L o valor máximo do nível de cinza.

2.4.2 Contrast-limited Adaptive Histogram Equalization (CLAHE)

A técnica de realce de contraste CLAHE foi desenvolvida por Pizer et al. (1990), consistindo em uma variação de equalização de histograma, com o diferencial de que, na CLAHE, a equalização é adaptativa com limitação de contraste. Tal método propõe um algoritmo que ajusta o histograma original da imagem em um outro histograma pré-definido, redistribuindo, posteriormente, os valores excedentes em outras intensidades, ou seja, aqueles que não se encaixaram na distribuição, antes de computar a função de distribuição cumulativa (CARNEIRO et al., 2019). A Equação 2.2 apresenta o cálculo efetuado para o processamento da CLAHE:

$$g = [g_{min} - g_{max}]p(f) + g_{min} \quad (2.2)$$

em que g é o novo valor de pixel computado, g_{max} e g_{min} significam o máximo e o mínimo valor do pixel, respectivamente, e $p(f)$ é a função de probabilidade de distribuição acumulada.

2.4.3 Quantização

A quantização de um imagem digital consiste em agrupar a gama de cores da imagem, o que acarreta na quantização da informação de cor de cada pixel da imagem. O processo de quantização transforma um conjunto de cores com M elementos em um conjunto de cores com N elementos, onde $M > N$ (NASCIMENTO et al., 2012). Por exemplo, em uma imagem de tons de cinza, o conjunto de cores e entrada é subdividido em conjuntos menores denominados intervalos de quantização ou células de quantização. Todas as cores de uma célula de quantização assumem um mesmo valor de saída (um determinado nível de

quantização), que corresponde ao calor representante dos elementos da célula (MIRANDA et al., 2015).

De acordo com Nascimento et al. (2012), dentre as formas para determinar as células de quantização, a escolha mais natural e simples à primeira vista, consiste em dividir o espaço de cor em células congruentes e em cada célula tomar o seu “centro” como sendo o nível de quantização associado. E no caso de quantização escalar com L níveis, as células de quantização são intervalos (c_{i-1}, c_i) de igual comprimento e em cada célula o valor de quantização é dado pela média, como apresentado na Equação 2.3:

$$q_i = \frac{c_i + c_{i-1}}{2}, 1 \leq i \leq L \quad (2.3)$$

2.5 Índices de diversidade

O termo diversidade, em ecologia, pode ser definido como a variedade e a variabilidade entre os organismos vivos e os complexos ecológicos em que ocorrem. Uma medida de diversidade é um parâmetro extremamente reducionista que objetiva expressar toda a complexidade estrutural de uma comunidade ecológica através de um único número (NASCIMENTO et al., 2012). A Tabela 1 apresenta uma analogia entre os termos utilizados na biologia em correspondência com o presente método.

Tabela 1 – Índice de Diversidade

Metodologia Proposta	Ecologia
Região de Interesse da imagem	Comunidade
Níveis de Cinza da Imagem	Espécies
Píxels da Imagem	Indivíduos

2.5.1 Índice de Shannon

Originado da teoria da informação (SHANNON, 2001), o Índice de Shannon assume que os indivíduos são randomicamente amostrados a partir de uma comunidade infinitamente grande, e que todas as espécies estão representadas na amostra. O Índice de Shannon é calculado conforme a Equação 2.4,

$$H' = - \sum_{i=1}^s p_i \ln p_i \quad (2.4)$$

onde, S é o total de espécies, \ln é o logarítmico natural, p_i a proporção de indivíduos pertencentes a espécie i na amostra, calculado com a Equação 2.5,

$$p_i = \frac{n_i}{N} \quad (2.5)$$

e n_i é o número de indivíduos na espécie i na amostra e N é o número total de indivíduos na comunidade.

2.5.2 Índice de Simpson

Proposto em 1949, por E. H Simpson (SIMPSON, 1949), O Índice de Simpson (D) é a medida de probabilidade de dois indivíduos selecionados aleatoriamente de uma comunidade infinitamente grande, pertencerem à mesma espécie. O Índice é calculado conforme Equação 2.6,

$$D = 1 - \sum_{i=1}^s p_i^2 \quad (2.6)$$

onde, p_i é a proporção de indivíduos pertencentes a espécie i na comunidade, calculado com a equação 2.5, n_i o número de indivíduos na espécie i e N é o número total de indivíduos na comunidade. S é o total de espécies predominante na comunidade.

2.5.3 Índice de Margalef

Índice de Margalef (D) (MARGALEF, 1969), é usado na ecologia para estimar a biodiversidade de uma comunidade com base na distribuição numérica dos indivíduos das diferentes espécies em função do número total de indivíduos existentes na amostra analisada. O Índice é calculado conforme Equação 2.7,

$$D = \frac{S - 1}{\ln(N)} \quad (2.7)$$

onde, S é o número de espécies e $\ln(N)$ é o logaritmo do número de indivíduos pertencente a comunidade

2.5.4 Índice de McIntosh

O Índice de McIntosh foi proposto por (MCINTOSH, 1967). A comunidade pode ser vista como um ponto em um hiper volume S -dimensional e a distância euclidiana da comunidade para a origem pode ser utilizada como uma medida de diversidade. É uma medida de probabilidade de dois indivíduos selecionados aleatoriamente de uma comunidade infinitamente grande pertencerem a mesma espécie (ARAÚJO et al., 2017). O índice de diversidade de McIntosh (D) é estimado através das seguintes Equações 2.8,

$$D = \frac{N - U}{N - \sqrt{N}} \quad (2.8)$$

onde, N é o número total de indivíduos na amostra e U é dado pela expressão 2.9,

$$U = \sqrt{\sum n_i^2} \quad (2.9)$$

onde, n_i é o número de indivíduos na espécie i e o somatório é realizado sobre todas as espécies. U é a distância euclidiana da comunidade desde a origem quando plotada em um hiper volume S -dimensional.

2.6 Reconhecimento de Padrões

Entende-se por padrão as propriedades que possibilitam o agrupamento de objetos semelhantes dentro de uma determinada classe ou categoria, mediante a interpretação de dados de entrada, que permitam a extração das características relevantes desses objetos (CASTRO; PRADO, 2002).

O reconhecimento de padrões é uma tarefa comumente utilizada tanto para sistemas computadorizados como pelo próprio ser humano. Muitas técnicas ilusionistas se baseiam no reconhecimento de padrões, assim como há várias aplicações computacionais que conseguem reconhecer vozes, imagens, vídeos, etc. Para [Wizbicki e Battisti \(2014\)](#), a base dessa técnica é classificar as informações baseando-se em um conhecimento inicial ou informações estatísticas dos próprios padrões. Quando falamos de reconhecimento de padrões gráficos em sistemas computacionais, estamos falando de visão computacional.

O uso do reconhecimento de padrões é recorrente para discriminar e classificar possíveis alterações em imagens médicas, determinando a presença ou ausência da doença. Após a extração de características, geralmente utiliza-se o reconhecimento de padrões para detectar as possíveis alterações nas imagens e classificar as possíveis anomalias ou não da imagem que desencadeiam a doença. Foi utilizado a ferramenta WEKA para realizar a classificação da pesquisa proposta.

Weka é uma coleção de algoritmos de aprendizado de máquina para tarefas de mineração de dados. Ele contém ferramentas para preparação de dados, classificação, regressão, agrupamento, mineração de regras de associação e visualização (WEKA, 2020).

Para o reconhecimento de padrões desta metodologia, baseado em estudos sobre classificadores levando em consideração seu desempenho, facilidade de adaptação nos experimentos, eficácia e junção com as ferramentas de extração de características em imagens. Embasado nestes critérios, foram escolhidos os seguintes classificadores: *Random Forest*, *Sequential Minimal Optimization* (SMO), *Multi Layer Perceptron* (MLP) e *Instance Based Learning* (IBK).

O *Random Forest* é um classificador composto por uma coleção de árvores, onde são aleatoriamente independentes e identicamente distribuídas e cada árvore vota na classe mais popular, sendo a escolhida para o objeto (OSHIRO, 2013).

O SMO é um dos principais métodos atuais para resolver o problema de programação quadrática que surge durante o treinamento de uma máquina de vetores de suporte (SVM). Este método, em certa medida, pode diminuir o grau de dificuldade de um problema de programação quadrática através de estratégias de decomposição. Esses proble-

mas são resolvidos analiticamente, permitindo que o SMO manipule um grande conjunto de treinamento e realize a distinção dos padrões entre os conjuntos de dados avaliados (ZENG et al., 2008).

O MLP é uma rede neural *feedforward*, que consiste em uma rede neural artificial em que as conexões entre os nós não formam um ciclo. É composta em camadas na qual a informação flui unidirecionalmente da camada de entrada para a camada de saída, passando pelas camadas ocultas. Cada conexão entre neurônios tem seu próprio peso. Perceptrons para a mesma camada têm a mesma função de ativação. Em geral, é um conexão para as camadas ocultas. Dependendo da aplicação, a camada de saída também pode ser uma conexão ou uma função linear (TAUD; MAS, 2018).

O IBK usa uma abordagem bastante simples de armazenar os dados de treinamento e classificar novos dados não vistos calculando a distância do exemplo mais semelhante já armazenado. O algoritmo usa o método de votação para decidir a classificação do novo exemplo e o número de votos é denotado pelo valor k onde, o valor de k precisa ser ímpar para evitar situações de empate (KANWAL; BOSTANCI, 2016).

2.7 Métricas de Validação

Para avaliar o desempenho dos classificadores, geralmente são usados métricas para validar a relevância da metodologia, onde são comumente utilizados as seguintes métricas: Acurácia (A), Sensibilidade (S) e Especificidade (E). Essas métricas fazem o uso da matriz de confusão, que faz a classificação correta e incorreta das classes, agrupando os resultados em quatro classes, respectivamente: Verdadeiro Positivo (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN).

- VP - Casos onde a método define como melanoma e o especialista confirma que é melanoma.
- FP - Casos onde a método define como melanoma, mas a marcação do especialista diz ser não melanoma.
- VN - Casos onde, tanto a marcação do método quanto a do especialista, define como não melanoma.
- FN - Casos onde o método diz se tratar de um não melanoma, mas o especialista define como melanoma.

A Tabela 2 apresenta a matriz de confusão.

Acurácia (A): É a proporção de predições corretas, sem levar em consideração o que é positivo e o que é negativo. Esta medida é altamente suscetível a desbalanceamentos do conjunto de dados e pode facilmente induzir a uma conclusão errada sobre o desempenho do sistema. Representado pela Equação 2.10.

Tabela 2 – Matriz de confusão

Resultado	Melanoma	Ausente
Positivo	Verdadeiro Positivo - VP	Falso Negativo - FN
Negativo	Falso Positivo - FP	Verdadeiro Negativo - VN

$$A = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.10)$$

Sensibilidade (S): É a proporção de verdadeiros positivos, isto é, a capacidade do sistema em prever corretamente a condição para casos que realmente a têm. Representado pela Equação 2.11.

$$S = \frac{VP}{VP + FN} \quad (2.11)$$

Especificidade (E): É a proporção de verdadeiros negativos, isto é, a capacidade do sistema em prever corretamente a ausência da condição para casos que realmente não a têm. Representado pela Equação 2.12.

$$E = \frac{VN}{VN + FP} \quad (2.12)$$

A análise ROC (*Receiver Operating Characteristic*) é uma ferramenta amplamente difundida para avaliar o desempenho de testes de diagnósticos na medicina. A AUC (*area under the ROC curve*) é uma maneira de resumir a curva ROC em um único valor, agregando todos os limiares da ROC. Como visto em Krohling, Paula e Behlau (2016), a curva ROC é uma ferramenta binária cujo valor varia de 0,0 até 1,0 e o limiar entre a classe é 0,5. Ou seja, acima desse limite, o algoritmo classifica em uma classe e abaixo na outra classe. Além disso, o AUC possui cinco graus de classificação: Excelente (0,9 a 1), boa (0,8 a 0,9), razoável (0,7 a 0,8), ruim (0,6 a 0,7) e não discriminatória (0,5 a 0,6).

Para avaliar a concordância do experimento é usado o método estatístico de cálculo do Coeficiente Kappa (K). Sendo utilizado para avaliar a reprodutibilidade dos resultados na validação. Este resultado quanto mais próximo de 1, maior será a concordância do experimento. A Tabela 3 representa os níveis de concordância do K.

Tabela 3 – Tabela de Concordância do Coeficiente Kappa.

Valor do Coeficiente KAPPA	Nível de Concordância
<0	Não existe concordância
Entre 0 e 0,2	Concordância Mínima
Entre 0,21 e 0,4	Concordância Razoável
Entre 0,41 e 0,6	Concordância Moderada
Entre 0,61 e 0,8	Concordância Substancial
Entre 0,81 e 1	Concordância Perfeita

No cálculo do K , P_o é a taxa de aceitação relativa e P_e é a taxa hipotética da aceitação. Representado pela Equação 2.13.

$$K = \frac{P_o - P_e}{1 + P_e} \quad (2.13)$$

As métricas citadas acima, tem como finalidade estimar o desempenho da metodologia realizada neste trabalho, para determinar se os resultados obtidos foram relevantes ou não e também apontar os pontos que foram positivos e negativos para que seja aplicado melhorias em trabalhos futuros para essa pesquisa.

3 Trabalhos Relacionados

A literatura especializada oferece estudos relacionados a classificação do melanoma, assim como técnicas de extração de características. Nesta seção será abordado um resumo de alguns desses trabalhos.

Na metodologia de [Li e Shen \(2018\)](#) é proposto uma abordagem para segmentar e classificar as imagens de lesões de pele de forma simultânea através da técnica *Lesion Indexing Network* (LIN). Através de 2 CNNs profundas, FCRNs-88, treinadas com diferentes conjuntos de treinamento, para produzir o resultado da segmentação e classificação. Usa-se a técnica *Lesion Indexing Calculation Unit* (LICU) para medir a importância do pixel na decisão da classificação. Resultando em 85,7% de acurácia, 96,6% em especificidade e 49,0% na sensibilidade.

[Maia et al. \(2019\)](#) propõe uma metodologia para o diagnóstico do melanoma através das regras ABCD (Assimetria, borda, cor e diâmetro), com o uso da rede neural VGG16, *Inception* e *Resnet* para a extração de características. Realizando o reconhecimento de padrões com o classificador *Random Forest* e obtendo uma acurácia de 92%, sensibilidade em 92,5% e especificidade de 91,8%.

no trabalho de [Saba et al. \(2019\)](#) é proposto uma abordagem automatizada para detecção e reconhecimento de lesões cutâneas usando uma *deep convolutional neural network* (DCNN). A DCNN possui três etapas para segmentação e reconhecimento de lesão: (a) aumento de dados e contraste aprimorado, (b) identificação de lesão com base em valor de cor e extração de limite de lesão, e (c) extração, fusão e seleção de recursos para reconhecimento. Foi utilizado o classificador *Multi Layer Perceptron* para classificação e atingiu a melhor precisão de 98,4% de acurácia.

No trabalho de [Ünver e Ayan \(2019\)](#) mostra uma metodologia para segmentação de lesões cutâneas em imagens dermatoscópicas combinando o algoritmo de segmentação *GrabCut* e uma rede neural convolucional profunda (DCNN) denominada *You Only Look Once* (YOLO) para classificação. Foram obtidos os resultados de 92,99% de acurácia, 83,63% de sensibilidade e 94,02% de especificidade.

Na abordagem de [Adegun e Viriri \(2019\)](#) é proposto um método baseado no aprendizado profundo para a detecção e segmentação automática de lesões de melanoma, utilizando Rede Neural Convolucional (RNC) para extração de características e o classificador *softmax* para classificação das lesões. O método alcançou uma precisão de 95% de acurácia, 97% de sensibilidade e 96% de especificidade.

[Banerjee et al. \(2020\)](#) propõe um algoritmo baseado em aprendizagem profunda *You Only Look Once* (YOLO), que é baseado na aplicação de *deep convolutional neural network* (DCNN) para detectar melanoma a partir de imagens dermatoscópicas e digitais, aplicando algoritmo baseado em grafos para segmentação e regra do ABCD para extração de

características. Resultando em 97,5% de acurácia, especificidade e sensibilidade.

Na metodologia de [Kumar et al. \(2020\)](#) propõe um sistema que classifica uma imagem de lesão da pele como cancerosa ou não cancerosa utilizando o agrupamento *fuzzy C-means* para segmentação. Para classificação uma a rede neural artificial (RNA) é treinada usando o algoritmo de evolução diferencial (DE). O resultado mostra que a técnica proposta detecta efetivamente o câncer de pele e apresenta acurácia de 97,4% de acurácia, 92% de especificidade e 90% de sensibilidade.

Os trabalhos relacionados acima apresentaram resultados promissores na detecção e diagnóstico do melanoma e lesões de pele, porém alguns apresentaram dificuldades na execução do método. Como no trabalho de [Saba et al. \(2019\)](#), que poderia ter sido aplicado outras métricas para validar suas pesquisas. No projetos de [Li e Shen \(2018\)](#) e [Ünver e Ayan \(2019\)](#) poderia ser empregado técnicas para melhorar a sensibilidade.

A maioria dos trabalhos citados acima, utilizam descritores baseados em forma, seguindo as regras ABCD e descritores baseados em redes neurais, com isso, nesta pesquisa pretende-se utilizar uma nova abordagem com descritores de textura baseado em índices de diversidade para verificar a relevância da análise de textura em comparação aos descritores de forma e aos baseados em redes neurais, também aumentar a acurácia e melhorar os valores da sensibilidade e especificidade.

4 Metodologia

A metodologia proposta neste trabalho segue as etapas da Figura 3. Na primeira etapa, é feita a aquisição das imagens oriundas da base PH2 (MENDONCA et al., 2015). A segunda etapa, é o pré-processamento, onde técnicas de processamento de imagens são aplicadas de modo a evidenciar com mais destaque as estruturas contidas nas imagens. Na terceira etapa, é realizada a extração de características, através dos índices de diversidade. Na quarta etapa, a classificação em melanoma ou não melanoma, foram utilizados os classificadores *Random Forest*, SMO, MLP e IBK. O processo é finalizado com a validação dos resultados.




Figura 3 – Metodologia proposta.

4.1 Aquisição das Imagens

O banco de dados PH2 foi criado principalmente para disponibilizar um conjunto de dados comum que pode ser usado para a avaliação de desempenho de diferentes sistemas de diagnóstico auxiliado por computador de imagens dermatoscópicas (MENDONCA et al., 2015). A base possui 200 imagens dermatoscópicas divididas em 40 imagens de melanoma e 160 imagens de não melanoma, com 8bits e resolução de 768x560 *pixels*.

Este trabalho utiliza *Region of Interest* (ROI) adquiridas da base PH2. Para a concretização desse trabalho, foram utilizadas 200 ROIs de imagens de lesões na pele; sendo 160 ROIs sem a presença de melanoma e 40 ROIs com melanoma. Na Figura 4 temos duas amostras da base.




Figura 4 – Exemplos de imagens contidas na base PH2.

4.2 Pré-Processamento

Na metodologia utiliza-se técnica de Equalização de Histograma para um espalhamento da distribuição dos níveis de cinza ao longo de toda a escala de contraste. Tal técnica tem a finalidade de aumentar a detectabilidade de aspectos da imagem. Na Figura 5 vemos a imagem original (a) e a imagem com a técnica aplicada (b). Na Figura 6 vemos seus respectivos histogramas.



Figura 5 – (a) Imagem Original e (b) Imagem Equalizada.

A técnica de equalização adaptativa de histograma com limitação de contraste (CLAHE) foi utilizada para gerar uma nova representação da imagem com realce de contraste. Essa técnica separa a imagem em regiões contextuais e aplica a equalização de histograma em cada uma delas. Na Figura 7 vemos a imagem original (a) e a imagem com a técnica aplicada (b). Na Figura 8 vemos seus respectivos histogramas.




Figura 6 – Histograma da Imagem Original e da Imagem Equalizada.



Figura 7 – (a) Imagem Original e (b) Imagem Realçada.




Figura 8 – Histograma da Imagem Original e da Imagem Realçada.

A metodologia utiliza de quantização (Figura 9). A proposta desta abordagem é investigar se uma região com menos espécies produz um resultado mais homogêneo e, desta forma, auxiliar os índices de diversidade. Neste trabalho, os valores de 7, 6, 5 e 4 bits foram definidos para aplicação da técnica, com o objetivo de obter uma variância gradual. As imagens foram geradas a partir da divisão dos *pixels* em subgrupos, onde, os elementos de

cada subgrupo assume o valor do *pixel* central, tornando a população mais homogênea.




Figura 9 – Quantizações aplicadas na metodologia.

4.3 Extração de Características

Após o pré-processamento das imagens, inicia-se a fase de extração de características baseada em textura. Nesta etapa serão obtidos valores que caracterizam a textura da lesão na pele. Neste trabalho, são utilizados quatro índices de diversidade, sendo eles: índice de Margalef, McIntosh, Shannon e Simpson.

Para a utilização destes índices em imagens, é necessário um mapeamento de conceitos de tal forma, que uma comunidade passas a ser interpretada como uma imagem e as espécies são as intensidades de *pixels* presentes na imagem (REIS et al., 2012).

De posse desse mapeamento de conceitos, é aplicada segmentação para evidenciar a região de interesse (ROI), onde foram obtidos os índices de diversidade, criando um vetor de características. A ROI cobre regiões significativas da imagem que, para esse trabalho, trata-se da região da lesão na pele. Para a geração do vetor de características, foram calculados todos os índices para a ROI selecionada gerando um vetor de 4 elementos, um para cada índice de diversidade.

Por fim, esses índices descrevem as texturas das imagens e os atributos fornecidos buscam reconhecer as medidas de homogeneidade ou heterogeneidade da ROI, servindo como parâmetros de entrada para os classificadores utilizados e permitindo a categorização em melanoma e não melanoma.

4.4 Classificação e Validação dos Resultados

Para a classificação, foi utilizado a ferramenta suíte de algoritmos de mineração de dados e Aprendizado de Máquina WEKA, que contém algoritmos para pré-processamento de dados, classificação, regressão, agrupamento, regras de associação e visualização.

Foram selecionados os algoritmos *Radom Forest*, SMO, MLP e IBK, por apresentarem bons resultados e pelo fato de serem rigorosos na presença de ruídos no processo de classificação, também utilizam descritores que se baseiam em comportamento dentro de comunidades, sendo uma boa escolha para a classificação da metodologia.

Utilizando os classificadores com parametrização padrão juntamente com a validação cruzada (*Cross Validation*) de *k-folds*, atribuindo o $k = 10$. Esse método tem como procedimento dividir os indivíduos em 10 grupos, separando o treino em 9 grupos e 1 grupo para teste, ocorrendo 10 cruzamentos alterando o grupo de teste, após realizar todos os cruzamentos é gerado uma média atribuída como resultado.

Por fim, após a etapa do reconhecimento de padrões é necessário a utilização de métricas para validar os resultados e analisar possíveis melhorias do mesmo. A metodologia proposta, utiliza métricas de validação recorrentes na área de processamento digital de imagens, sendo baseadas em estatísticas, respectivamente: Acurácia (A), Sensibilidade (S), Especificidade (E), Coeficiente Kappa (K) e Área Sobre a Curva (ROC).

5 Resultados e Discussões

Este capítulo apresenta e discute os resultados obtidos da aplicação da metodologia proposta neste trabalho, obtendo o resultado da classificação das ROIs das imagens de pele da base PH2 em melanoma e não melanoma. Foram feitos testes dos descritores de características para imagens em níveis de cinza, do canal vermelho, do canal verde e do canal azul, com o intuito de verificar o potencial dos descritores de textura em cada uma dessas representações da imagem. Para cada imagem são calculados quatro atributos, para todos os experimentos.

As Tabelas apresentadas neste Capítulo, são uma síntese com os melhores resultados obtidos entre os classificadores *Random Forest*, IBK, MLP e SMO nesta metodologia, através da extração de características de textura realizadas a partir dos índices de diversidade especificados na Seção 2.5 e utilizando os classificadores descritos na Seção 2.6 para o reconhecimento de padrões das imagens de pele.

A Tabela 4 apresenta os resultados dos testes para as imagens originais, com e sem quantização.

Sem Quantização						
Espaço de Análise	A(%)	S(%)	E(%)	ROC	Kappa	Classificador
Níveis de cinza	78	90	30	0,717	0.2254	Random Forest
Canal Vermelho	81,5	93,13	35	0,750	0.3273	Random Forest
Canal Azul	75,5	84,38	40	0,622	0.2415	IBK
Canal Verde	77	86,25	40	0,631	0.2675	IBK
Com Quantização de 7 bits						
Espaço de Análise	A(%)	S(%)	E(%)	ROC	Kappa	Classificador
Níveis de cinza	78	95	10	0,563	0,0678	Random Forest
Canal Vermelho	79	90	35	0,778	0,2759	Random Forest
Canal Azul	71,5	83,13	25	0,541	0,0836	IBK
Canal Verde	77	93,13	12,5	0,658	0,0726	Random Forest

Tabela 4 – Resultado dos testes utilizando imagens sem nenhum melhoramento de contraste.

De acordo com a Tabela 4, o classificador *Random Forest* obteve o melhor resultado em imagens com canal vermelho e sem quantização, com uma taxa de acurácia de 81,5%, uma sensibilidade de 93,13%, especificidade de 35%, uma curva ROC de 0,750 e um Kappa de 0,3273, indicando que o classificador apresenta uma razoável capacidade de diagnóstico, de acordo com a Tabela 3. O resultado menos significativo foi do classificador IBK nas imagens comuns com canal azul e com quantização, com taxa de acurácia de 71,5%, curva ROC de 0,541 e Kappa de 0,0836. Como podemos ver na Tabela 4, o classificador IBK foi capaz de identificar um número razoável de casos com a doença, como mostra a sensibi-

lidade de 83,13%. Um número baixo de casos que não têm a doença, com especificidade de 25%.

A Tabela 5 apresenta os resultados dos testes para as imagens com Equalização do histograma, com e sem quantização.

Sem Quantização						
Espaço de Análise	A(%)	S(%)	E(%)	ROC	Kappa	Classificador
Níveis de cinza	86	96,88	42,5	0.885	0.4737	MLP
Canal Vermelho	85	92,5	55	0.807	0.5033	Random Forest
Canal Azul	87,5	95,63	55	0.887	0.5645	MLP
Canal Verde	86	96,88	42,5	0.893	0.4737	MLP
Com Quantização de 7 bits						
Espaço de Análise	A(%)	S(%)	E(%)	ROC	Kappa	Classificador
Níveis de cinza	88	96,25	55	0.873	0.5775	MLP
Canal Vermelho	87	95	55	0.883	0.5517	MLP
Canal Azul	88	95	60	0.816	0.5946	Random Forest
Canal Verde	86,5	95,63	50	0.87	0.5196	MLP

Tabela 5 – Resultado dos testes utilizando imagens realçadas com Equalização do Histograma.

Dos resultados exibidos na Tabela 5, o classificador *Random Forest* em conjunto com as imagens com canal azul e com quantização obteve o melhor resultado, com uma taxa de acurácia de 88%, uma sensibilidade de 95%, especificidade de 60%, uma curva ROC de 0,816 e Kappa de 0,5946, indicando que o classificador apresenta uma moderada capacidade de diagnóstico, de acordo com a Tabela 3. O classificador MLP, tanto para as imagens em níveis de cinza quanto para o canal verde, sem quantização, obtiveram o resultado menos significativo, com uma taxa de acurácia de 86%, curva ROC 0,885 e Kappa de 0,4737. Foi observado na Tabela 5, que o classificador foi capaz de identificar um número alto de casos com doença, como mostra a sensibilidade de 86%, porém, uma quantidade mediana de casos que não têm a doença, com especificidade de 42,5%.

A Tabela 6 demonstra os resultados para as imagens com equalização de CLAHE, com e sem quantização. Entre os resultados obtidos, o classificador SMO obteve o melhor resultado nas imagens em níveis de cinza e com equalização, com uma taxa de acurácia de 90,5%, uma sensibilidade de 96,88%, especificidade de 62,5%, uma curva ROC de 0,800 e uma Kappa de 0,669, indicando que o classificador apresenta uma capacidade de diagnóstico substancial, de acordo com a Tabela 3. O pior resultado foi do classificador SMO nas imagens com canal azul e sem quantização, com taxa de acurácia de 89%, curva ROC de 0,781 e Kappa de 0,6207. Como podemos observar na Tabela 6, o classificador identificou um número alto de casos com doença, como mostra a sensibilidade de 89% e uma quantidade razoável de casos sem a doença, com especificidade de 60%.

Imagens Originais e CLAHE						
Sem Quantização						
Espaço de Análise	A(%)	S(%)	E(%)	ROC	Kappa	Classificador
Níveis de cinza	89,5	96,88	60	0.784	0.6341	SMO
Canal Vermelho	90	96,88	62,5	0.797	0.6552	SMO
Canal Azul	89	96,25	60	0.781	0.6207	SMO
Canal Verde	89,5	96,88	60	0.784	0.6341	SMO
Com Quantização de 7 bits						
Espaço de Análise	A(%)	S(%)	E(%)	ROC	Kappa	Classificador
Níveis de cinza	90,5%	97,5%	62,5%	0.800	0.669	SMO
Canal Vermelho	90%	97,5%	60%	0.788	0.6479	SMO
Canal Azul	90%	96,88%	62,5%	0.797	0.6552	SMO
Canal Verde	90%	97,5%	60%	0.788	0.6479	SMO

Tabela 6 – Resultado dos testes utilizando imagens realçadas com CLAHE.

A Tabela 7 apresenta uma comparação da metodologia deste trabalho com os trabalhos relacionados citados no Capítulo 3.

Tabela 7 – Comparativo com os Trabalhos Relacionados.

Trabalho	Metodologia	Base	A(%)	S(%)	E(%)
(LI; SHEN, 2018)	LIN CNN	ISIC	85,7	49	96,6
(MAIA et al., 2019)	Inception + Resnet + Random Forest	PH2	92	91,8	92,5
(ÜNVER; AYAN, 2019)	GrabCut + YOLO	PH2	92,99	83,63	94,02
(SABA et al., 2019)	DCNN + MLP	PH2	95,4	-	-
(ADEGUN; VIRIRI, 2019)	RNC + Softmax	PH2	95	97	95
(KUMAR et al., 2020)	FUZZY + ANN-DE	PH2	97,4	90	92
(BANERJEE et al., 2020)	ABCD + YOLO	PH2	97,5	97,5	97,5
Metodologia	Índices de diversidade + Quantização + SMO	PH2	90,5	97,5	62,5

A Tabela 7 faz um comparativo entre a metodologia proposta e os trabalhos relacionados, avaliando a acurácia, especificidade e sensibilidade. Este comparativo visa apenas ilustrar as predições obtidas em cada metodologia. No que diz respeito às métricas de desempenho utilizadas neste trabalho, o ideal para um sistema CADx é ter um bom equilíbrio entre as três métricas de avaliação (acurácia, sensibilidade e especificidade), pois, um bom método deve ser capaz de classificar com sucesso, tantos os casos de positivos (que possuem a doença) como os casos de negativos (que não possuem a doença).

É importante destacar a capacidade do método proposto em classificar corretamente as imagens que possuem melanoma, ou seja, alcançando uma sensibilidade de 97,5%.

Os resultados da metodologia proposta mostram-se promissores em comparação aos demais trabalhos. Na metodologia de Li e Shen (2018) foi obtido uma acurácia de 85,7%, sendo a menor taxa entre os trabalhos relacionados. O trabalho de Banerjee et al. (2020) obteve as melhores valores preditivos entre os trabalhos relacionados. Por fim, baseado nos valores das predições, a metodologia proposta apresentou resultados satisfatórios diante

da bibliografia.

5.0.1 Discussões

O método proposto apresentou-se promissor, no entanto, com algumas limitações em relação a outros trabalhos descritos no Capítulo 3. No entanto, é importante ponderar alguns aspectos, a saber:

1. Foi proposto e apresentado neste trabalho, técnicas capazes de descrever a textura das imagens, a partir de técnicas de outras áreas de estudo;
2. Os índices propostos nesse trabalho não necessitam de parametrização inicial e nem é necessário o redimensionamento das imagens, assim como, nos métodos utilizando CNN.
3. O método proposto é rápido, e consegue caracterizar cada imagem com uma média de 20 milésimos de segundo;
4. O método proposto produz apenas 4 (quatro) características para cada imagem, e conseguiu com isso, resultados bem promissores, uma vez que, descritores baseados em CNNs produzem milhares de atributos;
5. Por fim, acredita-se que os descritores propostos são robustos e capazes de caracterizar com sucesso, as imagens de melanoma e não-melanoma;

6 Conclusão

O presente estudo apresentou um método automático, com o uso dos Índices de Diversidade, em conjunto com reconhecimento de padrões, capaz de discriminar e classificar lesões na pele em melanoma ou não.

Os índices de diversidade, apresentaram-se moderados na tarefa de caracterização das regiões em melanoma e não melanoma.

Os resultados obtidos nas imagens quantizadas, demonstraram o desempenho próspero das técnicas de extração de textura pelos índices de diversidade com o classificador SMO, sendo confirmados pelo resultados da estatística *Kappa*, que é representado na Tabela 3.

No entanto, este trabalho contribuiu de forma positiva em duas distintas áreas. Sendo que na área da saúde, disponibilizou uma metodologia automática para auxílio no diagnóstico lesões na pele em melanoma e não melanoma, que apesar de não fornecer excelentes resultados mostram-se promissores. E na computação, com a adaptação de técnicas de outras áreas do conhecimento que serviram como descritores de textura, permitindo então, que sejam utilizados para caracterizações em outros tipos de imagens.

Ademais, como sugestão para trabalhos futuros, pretendendo-se:

- Implementar novos testes buscando melhorar ainda mais os resultados;
- Aumentar a quantidade e variabilidade das amostras de lesões utilizando mais bases de imagens;
- Aplicar os índices propostos para investigação de outras doenças; e,
- Aplicar os índices propostos em conjunto com outros descritores, inclusive, com abordagens de aprendizado profundo.

Referências

- ADEGUN, A. A.; VIRIRI, S. Deep learning-based system for automatic melanoma detection. *IEEE Access*, IEEE, v. 8, p. 7160–7172, 2019. Citado 2 vezes nas páginas 23 e 32.
- AMERICAN CANCER SOCIETY. *Early Detection, Diagnosis, And Staging*. 2019. Disponível em: <<https://www.cancer.org/cancer/melanoma-skin-cancer/detection-diagnosis-staging/how-diagnosed.html>>. Acesso em: 10 set. 2020. Citado na página 13.
- ARAÚJO, J. D. L. et al. Diagnóstico de glaucoma em imagens de fundo de olho utilizando os índices de diversidade de shannon e mcintosh. In: SBC. *Anais do XVII Workshop de Informática Médica*. [S.l.], 2017. Citado na página 18.
- AZEVEDO-MARQUES, P. M. d. Diagnóstico auxiliado por computador na radiologia. *Radiologia Brasileira*, SciELO Brasil, v. 34, n. 5, p. 285–293, 2001. Citado na página 14.
- BANERJEE, S. et al. Melanoma diagnosis using deep learning and fuzzy logic. *Diagnostics*, Multidisciplinary Digital Publishing Institute, v. 10, n. 8, p. 577, 2020. Citado 2 vezes nas páginas 23 e 32.
- BENEDETTI, J. Considerações gerais sobre radiação solar e danos à pele. 2019. Disponível em: <<https://www.msdmanuals.com/pt/casa/distúrbios-da-pele/radiação-solar-e-danos-à-pele/considerações-gerais-sobre-radiação-solar-e-danos-à-pele>>. Acesso em: 08.09.2020. Citado na página 11.
- CARNEIRO, P. C. et al. Clahe parameters effects on the quantitative and visual assessment of dense breast mammograms. *IEEE Latin America Transactions*, IEEE, v. 17, n. 05, p. 851–857, 2019. Citado na página 16.
- CASTRO, A. A. M. de; PRADO, P. P. L. do. Algoritmos para reconhecimento de padrões. *Revista Ciências Exatas*, v. 8, n. 2002, 2002. Citado na página 19.
- GUARAGNELLA, C.; RIZZI, M. Simple and accurate border detection algorithm for melanoma computer aided diagnosis. *Diagnostics*, v. 10, p. 1–7, 2020. Citado na página 11.
- GUERRA, R. L. et al. Custo-utilidade de terapias-alvo comparadas a dacarbazina para o tratamento de primeira linha do melanoma avançado não-cirúrgico e metastático no sistema Único de saúde do brasil. *Elsevier*, v. 20, p. 103–9, 2019. Citado na página 13.
- INCA, I. N. d. C. *Câncer de pele melanoma*. 2020. Disponível em: <<https://www.inca.gov.br/tipos-de-cancer/cancer-de-pele-melanoma>>. Acesso em: 22.08.2020. Citado na página 11.
- JANTSCH, G. E.; FELIPUSSI, S. C. Estudo de técnicas de pseudocoloração aplicadas a imagens radiográficas—uma abordagem aprimorada. *Scientia Plena*, v. 8, n. 11 (b), 2013. Citado na página 16.

- JÚNIOR, J. L. O. L.; SOARES, J. B. Desenvolvimento de metodologia para avaliação da adesividade agregado-ligante com o uso de processamento digital de imagem. *Transportes*, v. 27, n. 1, p. 82–95, 2019. Citado na página 14.
- KANWAL, N.; BOSTANCI, E. Comparative study of instance based learning and back propagation for classification problems. Lahore, 2016. Citado na página 20.
- KROHLING, L. L.; PAULA, K. M. P. de; BEHLAU, M. Roc curve of the pediatric voice related quality-of-life survey (p-vrql). *CEP, SciELO Brasil*, v. 29107, p. 372, 2016. Citado na página 21.
- KUMAR, M. et al. A de-ann inspired skin cancer detection approach using fuzzy c-means clustering. Springer, 2020. Citado 2 vezes nas páginas 24 e 32.
- LEITE, E. F.; ROSA, R. Análise do uso, ocupação e cobertura da terra na bacia hidrográfica do rio formiga, tocantins. *Observatorium: Revista Eletrônica de Geografia*, v. 4, n. 12, 2012. Citado na página 16.
- LI, Y.; SHEN, L. Skin lesion analysis towards melanoma detection using deep learning network. *Sensors, Multidisciplinary Digital Publishing Institute*, v. 18, n. 2, p. 556, 2018. Citado 3 vezes nas páginas 23, 24 e 32.
- MAIA, L. B. et al. Aprendizagem profunda aplicada ao diagnóstico de melanoma. Universidade Federal do Maranhão, 2019. Citado 2 vezes nas páginas 23 e 32.
- MARGALEF, R. Diversity and stability: a practical proposal and a model of interdependence. In: *Brookhaven symposia in biology*. [S.l.: s.n.], 1969. v. 22, p. 25–37. Citado na página 18.
- MCINTOSH, R. P. An index of diversity and the relation of certain concepts to diversity. *Ecology, Wiley Online Library*, v. 48, n. 3, p. 392–404, 1967. Citado na página 18.
- MENDONCA, T. et al. Ph2: A public database for the analysis of dermoscopic images. *Dermoscopy image analysis, CRC Press*, 2015. Citado na página 25.
- MIRANDA, F. B. d. et al. Quantização vetorial utilizando códigos esféricos. [sn], 2015. Citado na página 17.
- NASCIMENTO, L. B. et al. Classificação de nódulos pulmonares em maligno e benigno utilizando os índices de diversidade de shannon e de simpson. Universidade Federal do Maranhão, 2012. Citado 2 vezes nas páginas 16 e 17.
- OLIVEIRA, R. B. Método de detecção e classificação de lesões de pele em imagens digitais a partir do modelo chan-vese e máquina de vetor de suporte. 2012. Citado na página 11.
- OSHIRO, T. M. *Uma abordagem para a construção de uma única árvore a partir de uma Random Forest para classificação de bases de expressão gênica*. Monografia (Mestrado) — USP, São Paulo, 2013. Citado na página 19.
- PEREIRA, G. R. Desenvolvimento e uso de tecnologia utilizando realidade virtual e aumentada como forma de cooperação com o tratamento de problemas psíquicos, somáticos ou psicossomáticos. 2018. Citado na página 14.

- PIRES, G. M. et al. Arquitetura para um sistema de diagnóstico auxiliado por computador. In: *Anais do X Congresso Brasileiro de Informática em Saúde*. [S.l.: s.n.], 2006. Citado na página 14.
- PIZER, S. M. et al. Contrast-limited adaptive histogram equalization: speed and effectiveness. In: IEEE COMPUTER SOCIETY. [1990] *Proceedings of the First Conference on Visualization in Biomedical Computing*. [S.l.], 1990. p. 337–338. Citado na página 16.
- REIS, A. B. S. et al. Estudo de índices de diversidade como descritores de textura para classificação de imagens de faces. Universidade Federal do Maranhão, 2012. Citado na página 28.
- ROCHA, S. V. d. et al. Diferenciação do padrão de malignidade e benignidade de massas em imagens de mamografias usando padrões locais binários, geoestatística e índice de diversidade. Universidade Federal do Maranhão, 2014. Citado 2 vezes nas páginas 6 e 15.
- SABA, T. et al. Region extraction and classification of skin cancer: A heterogeneous framework of deep cnn features fusion and reduction. *Journal of medical systems*, Springer, v. 43, n. 9, p. 289, 2019. Citado 3 vezes nas páginas 23, 24 e 32.
- SHANNON, C. E. A mathematical theory of communication. *ACM SIGMOBILE mobile computing and communications review*, ACM New York, NY, USA, v. 5, n. 1, p. 3–55, 2001. Citado na página 17.
- SILVA, A. M. M. da; PATROCÍNIO, A. C.; SCHIABEL, H. Processamento e análise de imagens médicas. *Revista Brasileira de Física Médica*, v. 13, n. 1, p. 34–48, 2019. Citado na página 11.
- SIMPSON, E. H. Measurement of diversity. *nature*, Nature Publishing Group, v. 163, n. 4148, p. 688–688, 1949. Citado na página 18.
- TAUD, H.; MAS, J. Multilayer perceptron (mlp). In: *Geomatic Approaches for Modeling Land Change Scenarios*. [S.l.]: Springer, 2018. p. 451–455. Citado na página 20.
- ÜNVER, H. M.; AYAN, E. Skin lesion segmentation in dermoscopic images with combination of yolo and grabcut algorithm. *Diagnostics*, Multidisciplinary Digital Publishing Institute, v. 9, n. 3, p. 72, 2019. Citado 3 vezes nas páginas 23, 24 e 32.
- UTIYAMA, R. Y. et al. Melanoma metastático em cólon: relato de caso. *Arquivos Médicos*, v. 64, n. 3, p. 261–4, 2019. Citado na página 13.
- WEKA. 2020. Disponível em: <<https://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em: 10 set. 2020. Citado na página 19.
- WIZBICKI, A. S.; BATTISTI, G. Reconhecimento de padrões em imagens aplicando visão computacional. *Salão do Conhecimento*, v. 2, n. 01, 2014. Citado na página 19.
- ZENG, Z.-Q. et al. Fast training support vector machines using parallel sequential minimal optimization. In: IEEE. *2008 3rd international conference on intelligent system and knowledge engineering*. [S.l.], 2008. v. 1, p. 997–1001. Citado na página 20.



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA
“JOSÉ ALBANO DE MACEDO”**

Identificação do Tipo de Documento

- () Tese
- () Dissertação
- (X) Monografia
- () Artigo

Eu, **Alex William Leal**, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação **Classificação automática de imagens de texturas de pele em melanoma e não melanoma utilizando índices de diversidade** de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI, 26 de julho de 2021.

Alex William Leal

Assinatura