

UNIVERSIDADE FEDERAL DO MARANHÃO - UFMA
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA - CCET
CURSO DE CIÊNCIA DA COMPUTAÇÃO

MATEUS BARROS PINHEIRO

**METODOLOGIA PARA DIAGNÓSTICO DE CÂNCER DE PELE BASEADA
EM DESCRITORES DE TEXTURA USANDO MÁSCARAS DE LAWS E
PADRÕES LOCAIS BINÁRIOS**

São Luís
2020

MATEUS BARROS PINHEIRO

**METODOLOGIA PARA DIAGNÓSTICO DE CÂNCER DE PELE BASEADA
EM DESCRITORES DE TEXTURA USANDO MÁSCARAS DE LAWS E
PADRÕES LOCAIS BINÁRIOS**

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Orientadora: Profa. Dra. Simara Vieira da Rocha

São Luís
2020

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Pinheiro, Mateus Barros.

METODOLOGIA PARA DIAGNÓSTICO DE CÂNCER DE PELE BASEADA EM DESCRITORES DE TEXTURA USANDO MÁSCARAS DE LAWS E PADRÕES LOCAIS BINÁRIOS / Mateus Barros Pinheiro. - 2020. 46 p.

Orientador(a): Simara Vieira da Rocha.

Monografia (Graduação) - Curso de Ciência da Computação, Universidade Federal do Maranhão, São Luís, 2020.

1. Análise de Textura. 2. Máscaras de Laws. 3. Melanoma. 4. Reconhecimento de Padrões. I. Vieira da Rocha, Simara. II. Título.

MATEUS BARROS PINHEIRO

**METODOLOGIA PARA DIAGNÓSTICO DE CÂNCER DE PELE BASEADA
EM DESCRITORES DE TEXTURA USANDO MÁSCARAS DE LAWS E
PADRÕES LOCAIS BINÁRIOS**

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Aprovada em: / /

BANCA EXAMINADORA

Profª. Dra. Simara Vieira da Rocha (Orientadora)
Universidade Federal do Maranhão

Prof. Msc. Carlos Eduardo Portela Serra de Castro
Universidade Federal do Maranhão

Prof. Msc. Italo Francyles Santos da Silva
Universidade Federal do Maranhão

Aos meus amigos e irmãs.

Aos pais, pelo apoio e sustento.

Resumo

O melanoma é um câncer de alta malignidade que, mesmo sendo responsável por apenas algo entre 4% e 7% dos casos de câncer de pele, é responsável por 75% das mortes decorrentes desse grupo de câncer. Sua rápida evolução faz com que o seu diagnóstico precoce seja fundamental para aumentar as chances de vida dos pacientes. Por essa razão, faz-se necessário meios que possibilitem a automação do diagnóstico de forma que seja possível ao especialista ter um maior suporte durante o diagnóstico. Este trabalho propõe uma metodologia para o diagnóstico de melanomas fazendo uso exclusivo da textura presente nas imagens oriundas de exames de dermatoscopia. O objetivo é usar as máscaras de Laws (Laws Texture Energy Measure) para realçar regiões importantes nas imagens, bem como bordas e transições. As máscaras serão usadas juntamente com o Local Binary Pattern, a Grey Level Co-occurrence Matrix e o Índice de Diversidade de Shannon, buscando levar em consideração os relacionamentos dos padrões locais em regiões de grande importância para o estudo da textura. A classificação dos melanomas será realizada pela Máquina de Vetores de Suporte. Os melhores resultados foram obtidos com o uso da máscara L3L3 (responsável por realçar a intensidade dos níveis de cinza), onde foi possível chegar a uma média de acurácia de 90,68% analisando os pares de LBP com valores diferentes.

Palavras-chave: Melanoma; Máscaras de Laws; Análise de Textura; Reconhecimento de padrões.

Abstract

Melanoma is a highly malignant cancer that, even though it accounts for only between 4 % and 7 % of skin cancer cases, is responsible for 75 % of deaths resulting from this cancer group. Its rapid evolution makes its early diagnosis essential to increase patients' chances of life. For this reason, it is necessary to have means that enable the automation of the diagnosis so that it is possible for the specialist to have greater support during the diagnosis. This work proposes a methodology for the diagnosis of melanomas making exclusive use of the texture present in the images from dermoscopy exams. The goal is to use Laws masks (Laws Texture Energy Measure) to highlight important regions in images, as well as borders and transitions. The masks will be used together with the Local Binary Pattern, the Gray Level Co-occurrence Matrix and the Shannon Diversity Index, seeking to take into account the relationships of local patterns in regions of great importance for the study of texture. The classification of melanomas will be performed by the Support Vector Machine. The best results were obtained with the use of the L3L3 mask (responsible for enhancing the intensity of the gray levels), where it was possible to reach an average accuracy of 90.68% by analyzing the LBP pairs with different values.

Keywords: Melanoma; Laws Masks; Texture Analysis; Pattern Recognition.

Agradecimentos

A Deus, pela oportunidade e graça necessária para estudar.

A minha família, em especial minha mãe e pai pela paciência e cuidado que tiveram comigo; a minhas irmãs Carla e Rafaela, que sempre estiveram comigo; a minhas primas Cláudia, Clara, Duda, Lívia, Ívila, Ana Lídia, Patruicha, e a todos aqueles que a citação tornariam os agradecimentos o maior dos capítulos.

Aos meus amigos especiais: Amanda, Francisco, Gustavo, Kyu, Mariana e Saydna, pelo apoio em todos os momentos.

À turma de computação de 2016.1, em especial a Micael e Dayvson que ajudaram esses 5 anos a serem mais leves.

À professora Simara pela orientação, amizade e principalmente, pela paciência, com que me acompanha desde o início das nossas pesquisas.

Aos professores e funcionários do Departamento de Informática pelos seus ensinamentos.

Ao (doutor) Charles, por me permitir usar o supercomputador do serviço para executar os teste. E a todos aquele que me auxiliaram durante essa trajetória. Que Deus os pague.

Da nossa vida, em meio da jornada,

Achei-me numa selva tenebrosa,

Tendo perdido a verdadeira estrada.

Dante (Inferno, Canto primeiro)

Lista de Figuras

2.1	Exemplo de criação de uma máscara com kernel 3x3. $L3 * E3 = L3E3$. . .	21
2.2	Passos para a aplicação da convolução. Fonte: (LEMAÍTRE; RODOJEVIC, 2007)	22
2.3	Aplicação do filtro sobre o resultado da convolução. Fonte: (LEMAÍTRE; RODOJEVIC, 2007)	22
2.4	Cálculo do LBP. Adaptação de (ROCHA, 2014)	23
2.5	Criação da GLCM quando $P(i, j, 2, 0)$. Fonte: (ROCHA, 2014).	24
2.6	Geração do hiperplano. Fonte: Artificiência.com	26
2.7	Escolha do hiperplano. Fonte: Artificiência.com	27
3.1	Etapas da metodologia	29
3.2	Aplicação do realce logarítmico.	30
3.3	Representação da imagem.	31
3.4	Abordagem usada na GLCM. Fonte: (ROCHA, 2014)	34
3.5	Passos do reconhecimento. Adaptação de (BRAZ, 2008)	35

Lista de Tabelas

2.1	Filtros com kernel 3x3	21
3.1	Máscaras geradas.	31
4.1	Resultados da máscara L3L3 na abordagem 1 (diagonal principal)	39
4.2	Resultados da máscara E3L3 na abordagem 1 (diagonal principal)	40
4.3	Resultados da máscara S3L3 na abordagem 1 (diagonal principal)	40
4.4	Resultados da máscara L3L3 na abordagem 2 (matriz interna)	41
4.5	Resultados da máscara E3L3 na abordagem 2 (matriz interna)	41
4.6	Resultados da máscara S3L3 na abordagem 2 (matriz interna)	42
4.7	Comparação com trabalhos relacionados	45

Lista de Abreviações

ACS	<i>American Cancer Society</i>
FP	Falso Positivo
FN	Falso Negativo
GLCM	<i>Grey Level Co-occurrence Matrix</i>
GLRLM	<i>Grey-Level Run Length Matrix</i>
INCA	Instituto Nacional do Câncer
ISIC	<i>The International Skin Imaging Collaboration</i>
LBP	<i>Local Binary Pattern</i>
LTEM	<i>Laws Texture Energy Measure</i>
MPC	<i>Multilayer Perceptron Classifier</i>
MVS	Máquina de Vetores de Suporte
ROI	<i>Region Of Interest</i>
VP	Verdadeiro Positivo
VN	Verdadeiro Negativo

Sumário

1	Introdução	14
1.1	Objetivos	16
1.1.1	Objetivos Específicos	16
1.2	Trabalhos Relacionados	17
2	Fundamentação Teórica	19
2.1	Processamento de imagens	19
2.2	Realce logaritmico	20
2.3	Laws Texture Energy Measure (LTEM)	20
2.4	Local Binary Pattern (LBP)	23
2.5	Gray Level Co-occurrence Matrix (GLCM)	23
2.6	Índice de Diversidade	24
2.6.1	Índice de Diversidade de Shannon	25
2.7	Reconhecimento de padrões	25
2.7.1	Máquina de Vetores de Suporte	26
2.8	Validação dos Resultados	27
2.9	Considerações finais	28
3	Metodologia Proposta	29
3.1	Aquisição de imagens	29
3.2	Pré-processamento	30
3.3	Representação da Imagem	30
3.4	Extração de características	32
3.4.1	Índice de Diversidade de Shannon	33
3.5	Reconhecimento de Padrões	35
3.5.1	Máquina de Vetores de Suport	35
3.5.2	Validação dos Resultados	36
3.6	Considerações Finais	36
4	Resultados	38
4.0.1	Abordagem 1	38
4.0.2	Abordagem 2	40
4.1	Discussão	42
5	Conclusão	46
5.1	Trabalhos Futuros	47
	Referências	48

1 Introdução

O melanoma é um dos muitos tipos de câncer de pele existentes. Mesmo não sendo o mais comum entre os cânceres de pele é o que tem a maior periculosidade, dada a velocidade do seu desenvolvimento e a facilidade com que entra em estado de metástase (quando o câncer se espalha para outras regiões do corpo). Esse risco pode ser analisado a partir das estatísticas levantadas pela American Cancer Society (ACS, 2020).

Estima-se que os melanomas sejam responsáveis por 4% a 7% dos casos, enquanto os não melanomas (carcinomas) cheguem a uma incidência de 70% a 80%. Mesmo com uma incidência menor, os melanomas são responsáveis por 75% das mortes provenientes do câncer de pele (JAIN et al., 2015).

Segundo a American Cancer Society ACS (2020), apenas para o ano de 2020 nos Estados Unidos, estima-se que cerca de 100.350 novos casos de câncer melanoma serão diagnosticados, sendo 60.190 entre homens e 40.160 entre mulheres. Com uma das maiores taxas de mortes, cerca de 6.850 pessoas morrerão das 100 mil diagnosticadas: 4.610 homens e 2.240 mulheres.

Para o Brasil espera-se cerca de 8.450 novos casos no ano de 2020 segundo previsão do Instituto Nacional Do Câncer (INCA). Ainda segundo o INCA (2020), no ano de 2018 houve cerca de 1.791 óbitos oriundos de câncer de melanoma no Brasil, sendo 1.038 em homens e 753 em mulheres (INCA, 2020).

O melanoma tem origem nos melanócitos (células responsáveis por produzir melanina, substância que determina a cor da pele) e é mais comum em brancos podendo se desenvolver em qualquer parte do corpo humano. Por se iniciar na superfície da pele, o melanoma, quando em estágio avançado, pode facilmente evoluir e penetrar os vasos sanguíneos, sistema nervoso, ossos, etc. dificultando sua remoção e aumentando o risco de morte no paciente.

Esse é o motivo pelo qual o rápido diagnóstico precoce é fundamental para o aumento na sobrevivência dos pacientes. Quando o melanoma é diagnosticado no primeiro estágio da doença, a sobrevivência média de 5 anos é de cerca de 98%, no segundo estágio,

que é onde o melanoma apresenta o diâmetro entre 0,76 e 1,49 mm, a sobrevida cai para algo entre 87% e 94%. À medida que o diâmetro aumenta, estágio 3 e 4, a média da sobrevida pode cair para menos de 50% (JERANT et al., 2000).

São duas as possíveis formas de diagnosticar o câncer de pele (MAIA, 2015). A primeira é a Forma Invasiva, realizada por meio de uma biópsia, onde uma parte da pele é retirada e enviada para o laboratório para determinar a malignidade das células selecionadas. Esse método é mais custoso e causa mais incômodos para os pacientes, sendo usado quando a Forma Não Invasiva não surte um efeito imediato.

A Forma Não Invasiva consiste na avaliação visual da lesão. O especialista leva em conta alguns fatores que são comuns nos melanomas, como o contorno desregular, o tamanho das lesões, a transição de cores, etc. Para uma melhor análise, a técnica usada é a da dermatoscopia (FRANGE; ARRUDA; DALDON, 2012), onde o médico, com o auxílio do dermatoscópio, pode ampliar a visão das lesões. Há, entretanto, problemas que atrapalham no rápido diagnóstico dos melanomas, já que a análise visual é subjetiva e pode ser atrapalhada por fatores externos, tais como: cansaço e inexperiência do dermatologista; iluminação irregular do ambiente; lesões em estágios iniciais; etc.

Com o intuito de diminuir a margem de erro e tornar o diagnóstico de melanomas mais rápido, várias pesquisas são desenvolvidas em todo o mundo. As pesquisas buscam um meio de automação do diagnóstico de tal forma que seja possível ao médico consultar tais programas buscando uma segunda opinião.

Este trabalho busca, através da análise de textura das imagens de exames médicos, auxiliar na classificação dos possíveis melanomas, buscando contribuir para o avanço no diagnóstico dos cânceres de pele e permitir que mais pacientes possam descobrir ainda no estágio inicial a doença e iniciar o tratamento.

Para tal, uma metodologia foi proposta levando em conta desde a aquisição das imagens de exames médicos até a devida classificação dos melanomas. A metodologia busca fazer uso exclusivo da análise da textura presente nas ROIs, assim são levados em conta mais fatores do que quando usado apenas a análise de bordas, a transições de cores ou o diâmetro das lesões. Esses fatores, por meio da intensidade, posição e distância, levam em conta o relacionamento dos padrões presentes nas imagens.

Uma das etapas é a aplicação das máscaras de Laws (Laws Texture Energy Measure), capazes de realçar regiões das imagens de forma a aprimorar bordas, manchas, ondulações, transições, etc (LAWS, 1980), buscando assim contribuir para o aprimoramento dessas regiões que são importantes para o estudo da textura.

Juntamente às máscaras de Laws, foi feito o uso do Local Binary Pattern (LBP), tornando possível a análise dos relacionamentos dos pixels e não apenas o seu valor intrínseco. Essa combinação de técnicas permite que os pares de LBP localizados em bordas sobrepostas e em erupções cutâneas presentes nas ROIs sejam contabilizadas, permitindo uma melhor análise da textura das imagens.

Ademais, foram usadas outras técnicas que buscam quantificar os relacionamentos gerados no LBP, como a Grey Level Co-occurrence Matrix, a qual permite que os relacionamentos presentes em toda a imagem possam ser levados em conta simultaneamente por meio da matriz gerada.

1.1 Objetivos

O objetivo geral deste trabalho foi propor uma metodologia capaz de caracterizar e discriminar a textura de melanomas em imagens provenientes de exames de câncer de pele.

1.1.1 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Adaptar técnicas de realce de imagens que possibilitem uma melhor descrição das características de textura da imagem;
- Utilizar as Medidas de Textura de Energia de Laws para obtenção do aprimoramento das características das imagens;
- Estabelecer esquemas de representação da imagem utilizando Padrões Locais Binários;
- Estruturar a metodologia para discriminar por meio exclusivo da textura padrões em imagens com e sem melanoma; e,

- Avaliar a metodologia proposta através da realização de experimentos, utilizando a base pública disponível em The International Skin Imaging Collaboration.

1.2 Trabalhos Relacionados

Na literatura, há trabalhos que buscam contribuir para o diagnóstico do câncer de pele fazendo uso da análise de textura; alguns deles combinam a textura com outras técnicas buscando aprimorar a classificação dos melanomas.

Dos trabalhos desenvolvidos, vale destacar o de Sheha et al. (2012), onde é feito o uso da matriz GLCM combinada com o Multilayer Perceptron Classifier (MPC) para extração das características e classificação dos resultados. Nele foi possível obter 92% de acurácia, 91,6% de especificidade e 92,3% de sensibilidade fazendo uso exclusivo da análise de textura com 102 imagens da base pública D-Atlas (Dermoscopy Atlas).

Abdul-Wadood, George e Rasheed (2014) propõe uma metodologia que combina às matrizes GLCM e GLRLM (matriz de comprimento de corrida de cinzas) técnicas para extrair informações sobre as rugosidades das lesões. Uma acurácia de 92,5% foi alcançada nesse método. A base usada foi coletada no hospital de patologias do Iraque, contendo 80 amostras de casos com e sem melanoma.

Um outro trabalho importante é o de Masood, Al-Jumaily e Anam (2014). Nele as características são extraídas usando histogram-based fuzzy C-means chegando a uma acurácia de 90%, sensibilidade de 91% e especificidade de 89%. Foram analisadas 270 imagens clínicas de uma base própria. Os demais trabalhos fazem uso de outras técnicas combinadas à análise de textura, o que é diferente do proposto nesta pesquisa.

Outros trabalhos buscam fazer essa distinção das imagens de melanomas e não melanomas sem fazer análise da textura, usando apenas combinações de abordagens estruturais e geométricas. Destacam-se: (BOARO et al., 2020), que usa uma rede neural para estimar e classificar as características sob um conjunto de 4018 imagens da base pública ISIC.

Nida et al. (2019) usa a rede neural convolucional para extrair informações de cor e intensidade dos melanomas e não melanomas em uma base de 1276 imagens também provenientes da ISIC. Já (BISLA et al., 2019) usa uma técnica de Deep Convolutional

Generative Adversarial Networks para gerar as características. Esse caso usou múltiplas bases buscando o mais heterogeneidade; sua base era composta por 959 melanomas.

Todos os trabalhos citados, bem como a metodologia proposta por este, propõe uma metodologia para o diagnóstico de câncer de pele, com o intuito de classificar as imagens em melanomas e não melanoma. Bisla et al. (2019) difere das outras pesquisas por classificar 3 diferentes tipos de câncer simultaneamente.

Por fim, este trabalho está dividido em cinco capítulos: fundamentação teórica, onde são explicadas as técnicas usadas durante a pesquisa; metodologia, onde será explicado o passo a passo do que foi desenvolvido neste trabalho; resultados, onde discutiremos os resultados alcançados após a aplicação da metodologia; e, por fim, a conclusão.

2 Fundamentação Teórica

Neste capítulo será apresentada a fundamentação teórica usados no desenvolvimento desta pesquisa. Assim, serão abordados: conceitos fundamentais sobre o processamento de imagens, realce logarítmico, Laws texture energy measure, Local Binary Pattern, Grey Level Co-occurrence Matrix, Índice de Diversidade de Shannon, Reconhecimento de Padrões e Validação dos resultados.

2.1 Processamento de imagens

O processamento de imagens é um conjunto de técnicas que vão desde a aquisição até a correta interpretação das imagens e permite que computadores sejam capazes de analisar informações extraídas de uma cena. Cada uma das etapas tem sua peculiaridade e função específica, permitindo que quando usadas em conjunto possa-se obter uma melhoria significativa na forma como a imagem digital é representada, facilitando sua classificação e estudo.

Segundo Filho e Neto (1999), o processamento de imagens se inicia com a aquisição das imagens, sendo esta fase dependente do objeto de estudo. Passa-se para o pré-processamento das imagens, onde se busca melhorá-las de forma a remover ruídos, aprimorar características, etc. sem deturpar suas propriedades iniciais.

Em seguida, faz-se o uso da segmentação conforme a necessidade de separar a região de interesse (Region of Interest, ROI sigla em inglês), buscando retirar regiões que podem atrapalhar o estudo da imagem e que não têm grande influência na pesquisa. Essa etapa de segmentação é de grande valia para todo o processo, já que permite uma melhora significativa nos resultados finais.

Depois disso, passa-se então a extração de características que possam descrever a imagem digital de forma a contribuir para sua futura classificação, ou seja, busca-se representar a imagem por meio de dados obtidos sobre ela, permitindo um melhor manejo e representação da imagem.

Por fim, chega-se a etapa de classificação das imagens, onde se busca distribuir em grupos já pre-definidos as características extraídas. Nesta fase, o trabalho resume-se em rotular as características em grupos distintos permitindo sua classificação de acordo com suas propriedades.

Na sequência serão explicadas cada uma das etapas de processamento de imagens usadas neste trabalho, indo desde o pré-processamento até a classificação e validação dos resultados.

2.2 Realce logaritmico

O realce logaritmico é usado quando se deseja expandir/comprimir as intensidades dos valores dos pixels de uma dada imagem (GONZALEZ; WOODS; EDDINS, 2010). Ele expande os níveis de cinza mais escuros e comprime aqueles que se apresentam mais claros, o contrário também é válido quando o realce logaritmo inverso é aplicado. O realce é dado pela Equação 2.1:

$$g(x, y) = C * \log_{10}(p(x, y) + 1) \quad (2.1)$$

onde $g(x,y)$ é o novo valor do pixel, C é um fator definido pelos níveis de cinza da imagem que permitirão que os novos valores estejam entre 0 e o nível de cinza máximo; $p(x,y)$ é o valor do pixel da imagem na posição (x,y) e \log_{10} é a função que retorna o logaritmo na base 10 do valor passado.

2.3 Laws Texture Energy Measure (LTEM)

A Medida de Energia de Textura de Laws (LTEM, sigla em inglês) desenvolvida por Kenneth I. Laws é capaz de aguçar características que fazem parte da imagem, através da criação e aplicação de mascaras na imagem (LAWS, 1980). As mascaras são geradas a partir da combinação de filtros propostos por Laws mostrados na Tabela 2.1.

A combinação é feita através da multiplicação dos filtros escolhidos, tendo como resultado uma matriz quadrada de tamanho 3x3, 5x5 ou 7x7. O nome dos filtros é formado pela inicial da característica que ele realça, L para level (os tons de cinza), E para edge

(bordas), S para spot (ponto, mancha), W para wave (onda) e R para ripple (ondulação).

Tabela 2.1: Filtros com kernel 3x3

Filtro	Valor		
L3	1	2	1
E3	-2	0	1
S3	-1	2	-1

$$\begin{array}{c} \text{L3} \end{array} \begin{array}{|c|} \hline 1 \\ \hline 2 \\ \hline 1 \\ \hline \end{array} \times \begin{array}{|c|} \hline \text{E3} \\ \hline -2 \quad 0 \quad 1 \\ \hline \end{array} = \begin{array}{|c|} \hline \text{L3E3} \\ \hline -2 \quad 0 \quad 1 \\ \hline -4 \quad 0 \quad 2 \\ \hline -2 \quad 0 \quad 1 \\ \hline \end{array}$$

Figura 2.1: Exemplo de criação de uma máscara com kernel 3x3. $L3 * E3 = L3E3$

Um exemplo da geração de uma máscara é apresentado na Figura 2.1. Escolhidos dois filtros com mesmo tamanho, no caso o L3 e E3, é feito sua multiplicação e o resultado obtido é a máscara L3E3. Para gerar a LTEM é necessário seguir os seguintes passos (LEMAÏTRE; RODOJEVIC, 2007):

1. Aplicação da função de convolução em toda a imagem usando a máscara gerada pelos filtros escolhidos, como ilustrado na Figura 2.2; onde os valores relacionados ao x_i (com $i = 0 \dots L \times L$) são pertencentes a imagem de entrada, (2.2 a), e os relacionados a m_i (com $i = 0 \dots L \times L$) são os valores da máscara usada e onde Y_j é o resultado da convolução após multiplicar os números com respectivos índices e somá-los.
2. Aplicação de um filtro com o intuito de suavizar a convolução e gerar a LTEM, podendo ser este o filtro da média, o filtro da média absoluta ou o filtro do desvio padrão. O passo é mostrado na Figura 2.3, onde o filtro escolhido (b) é aplicado sobre a imagem resultante da etapa 1, (a), e gera um valor para o pixel de saída da imagem (c).

- Filtro da média:

$$g(x, y) = \frac{1}{N} \sum_{i=1}^N p_i \quad (2.2)$$




Figura 2.2: Passos para a aplicação da convolução. Fonte: (LEMAÍTRE; RODOJEVIC, 2007)

- Filtro da média absoluta:

$$g(x, y) = \left| \frac{1}{N} \sum_{i=1}^N p_i \right| \quad (2.3)$$

- Filtro do desvio padrão, onde μ é a média aritmética da mesma vizinhança:

$$g(x, y) = \sqrt{\frac{\sum_{i=1}^N (p_i - \mu)^2}{N}} \quad (2.4)$$




Figura 2.3: Aplicação do filtro sobre o resultado da convolução. Fonte: (LEMAÍTRE; RODOJEVIC, 2007)

Após aplicar os dois passos explicados, tem-se uma saída realçada pela máscara escolhida. Como é possível notar, para cada entrada há três saídas distintas (uma para cada filtro de suavização), ficando a critério da metodologia qual delas deve ser usada (LEMAÍTRE; RODOJEVIC, 2007).

2.4 Local Binary Pattern (LBP)

O Local Binary Pattern (LBP, sigla em inglês para Padrão Local Binário) é um descritor local de textura que funciona com a ideia de que uma textura pode depender de duas características levemente relacionadas, sendo elas o padrão e a intensidade (OJALA; PIETIKÄINEN; HARWOOD, 1996). Sua implementação pode ser realizada aplicando a fórmula 2.5 em todos os pixels da imagem.

$$LBP(x_c, y_c) = \sum_{n=0}^{n-1} S(i_n - i_c)2^n \quad (2.5)$$

Dada a Expressão 2.5, temos que LBP (x_c, y_c) representa o valor do LBP gerado, n é o número de pixels vizinhos ao pixel central (x_c, y_c) , i_c o pixel central, i_n o pixel na posição n e $S(x)$ uma função que devolve 0 se $x < 0$, e 1 caso contrário.

8	7	1	1	1	0	= 19
2	5	5	0	1	16	
0	3	1	0	0	0	
(a)	(b)	(c)	(d)	(e)		

Figura 2.4: Cálculo do LBP. Adaptação de (ROCHA, 2014)

Como exemplo da criação do LBP a Figura 2.4 mostra suas etapas. Em (a) é selecionada uma vizinhança de tamanho 3 x 3 do pixel central, nela é aplicada a função do LBP e os resultados são mostrados em (b). Em (d) é armazenado o resultado da multiplicação de (b) pela matriz de pesos (c) e por fim é obtido o LBP da imagem no pixel central, no caso do exemplo o seu valor é 19.

2.5 Gray Level Co-occurrence Matrix (GLCM)

A Gray Level Co-occurrence Matrix (GLCM, sigla em inglês para Matriz de Co-ocorrência de Níveis de Cinza) é capaz de descrever as relações entre um dado par de pixels, levando em conta a intensidade, a distância e o ângulo presente entre esses dois pixels. Por essa questão, se faz comum o uso de GLCM para obtenção do relacionamento de pixels presente em uma imagem, e logo após sua obtenção é feito a extração de medidas que

serão utilizadas para análise de textura.

A GLCM pode ser implementada em diferentes ângulos, tendo os de 0, 45, 90, 135 como mais comuns. A GLCM é denotada por $P(i, j, d, \theta)$, onde d equivale a distância entre os pixels, θ representa o ângulo entre os dois pixels e i e j representam os respectivos valores dos pixel 1 e pixel 2 (HARALICK; SHANMUGAM; DINSTEN, 1973).

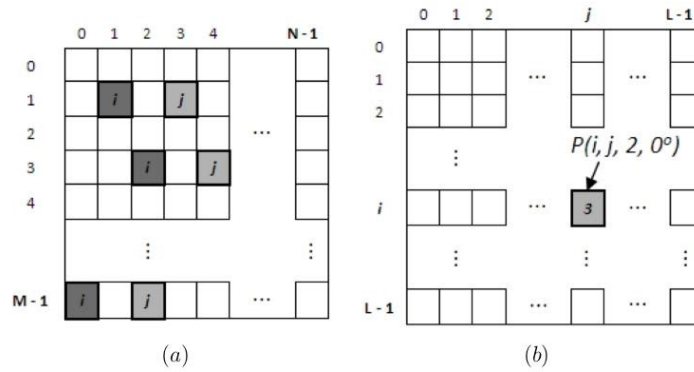


Figura 2.5: Criação da GLCM quando $P(i, j, 2, 0)$. Fonte: (ROCHA, 2014).

No exemplo de criação da GLCM na Figura 2.5 é mostrado com destaque em (a) os relacionamentos presentes na imagem de entrada que satisfazem as exigências nos níveis de cinza, nas distâncias entre pixels e o ângulo presente entre eles. Para cada relacionamento que satisfaz essas condições é incrementado na GLCM (b) a posição (i, j) da matriz que passa a armazenar esse relacionamento.

2.6 Índice de Diversidade

O índice de diversidade permite dimensionar a riqueza, a igualdade e a diversidade das espécies dos diferentes ambientes estudados, mostrando-se capaz de prever mudanças ambientais. Para tal, é necessário aplicá-lo sobre uma dada comunidade, está por sua vez é definida como um conjunto de espécies que ocorrem em um determinado local e tempo (MAGURRAN, 2004).

A diversidade aqui citada também se encontra relacionada ao seu significado na ecologia, onde se refere a variedade de espécies em uma comunidade ou região. Mais precisamente, a diversidade envolve dois fatores: 1) riqueza, que nomeia a quantidade de espécies e 2) abundância relativa, que contém a quantidade de indivíduos de determinada

espécie (MCINTOSH, 1967).

A peculiaridade dos índices de diversidade está no fato de que eles são capazes de expressar toda a complexidade estrutural de uma comunidade ecológica através de um único número (SANTOS, 2009), o que facilita o levantamento de dados e o estudo sobre comunidades.

2.6.1 Índice de Diversidade de Shannon

O índice de Shannon, dado pela Equação 2.6, é capaz de mostrar o grau de incerteza que existe em relação às espécies de um indivíduo escolhido de maneira arbitrária sobre uma dada população (SHANNON; WEAVER, 1949). Ele leva em consideração o número de espécies e as espécies dominantes.

$$H' = - \sum_{i=0}^S p_i \ln p_i \quad (2.6)$$

Para a Equação 2.6 tomamos S como o total de espécies e p_i como a proporção de indivíduos pertencentes a espécie i, podendo este ser logrado com o uso da Equação 2.7, onde n_i é o número de indivíduos na espécie i e N como o número de indivíduos presentes na comunidade.

$$p_i = \frac{n_i}{N} \quad (2.7)$$

2.7 Reconhecimento de padrões

O reconhecimento de padrões é o ato ou efeito de relacionar um conjunto de propriedades extraídas com etiquetas previamente conhecidas (PEDRINI; SCHWARTZ, 2008). Ainda segundo Pedrini e Schwartz (2008), o reconhecimento de padrões ocorre em dois passos:

- Classificação:

onde as propriedades já classificadas por um algoritmo de classificação são separadas conforme suas classes, e estas são compostas por amostras que apresentam características semelhantes.

- Reconhecimento:

onde uma amostra gerada da mesma população é reconhecida em comparação com as classes já existentes.

2.7.1 Máquina de Vetores de Suporte

A Máquina de Vetores de Suporte (MVS) é um conjunto de métodos de aprendizado supervisionado, que serve para classificar um conjunto de dados de entrada em duas possíveis classes. A qualidade do seu reconhecimento depende diretamente da qualidade da sua aprendizagem (treinamento).

Graças a necessidade do seu treinamento a MVS é um tipo de reconhecedor supervisionado, ou seja, precisa do levantamento de alguns dados para efetivar o reconhecimento (VAPNIK, 1998).

A ideia por trás da MVS é a utilização de um hiperplano, gerado através do aprendizado, que funciona como um separador de classes em diversas dimensões em um plano, com a maior margem de distância possível (SANTOS et al., 2002).

Para a geração de um ótimo hiperplano faz-se uso de vetores de suporte que estão diretamente ligados a construção de hiperplanos de margem máxima, como exemplificado nas Figuras 2.6, onde são mostrados 3 possíveis hiperplanos: o verde, amarelo e preto; e 2.7, que por sua vez mostra a escolha do hiperplano preto que apresenta a maior distância entre ambas as características.




Figura 2.6: Geração do hiperplano. Fonte: Artificiência.com




Figura 2.7: Escolha do hiperplano. Fonte: Artificiência.com

2.8 Validação dos Resultados

As ações a seguir buscam trazer meios de medir os resultados obtidos, a fim de analisá-los, compará-los e inculir a eles uma maior confiabilidade. De acordo com Bland (2000), são três as medidas estatísticas comumente calculadas sobre os resultados do reconhecimento.

Essas medidas são: Acurácia, Sensibilidade e a Especificidade; e são descritas a seguir, onde VP (Verdadeiro Positivo) ocorre quando o teste é positivo e o paciente tem a doença, VN (Verdadeiro Negativo) ocorre quando o teste é positivo e o paciente não tem a doença, FP (Falso Positivo) ocorre quando o teste é negativo e o paciente tem a doença e FN (Falso Negativo) ocorre quando o teste é negativo e o paciente não tem a doença (ROCHA, 2014).

- Acurácia: corresponde à taxa de classificação correta, ou seja, a razão entre o número de casos das amostras que foram classificados corretamente e o número total.

$$A = \frac{VP + VN}{VP + FP + VN + FN} \quad (2.8)$$

- Sensibilidade: corresponde à taxa de acertos ao relacionar uma imagem de melanoma com um resultado positivo, ou seja, a chance de classificar um doente.

$$S = \frac{VP}{VP + FN} \quad (2.9)$$

- Especificidade: corresponde à taxa de acertos ao relacionar uma imagem sem melanoma com um resultado negativo, ou seja, a chance de classificar um paciente sadio.

$$E = \frac{VN}{VN + FP} \quad (2.10)$$

2.9 Considerações finais

Neste capítulo foi apresentada a fundamentação teórica necessária para a compreensão das técnicas usadas na metodologia proposta. No próximo capítulo será descrita a metodologia desta pesquisa, mostrando quais os passos que foram seguidos para a classificação dos melanomas.

3 Metodologia Proposta

Este capítulo descreve as etapas propostas pela metodologia usada neste trabalho. As etapas são: aquisição de imagens, pré-processamento, representação da ROI, extração de características e reconhecimento de padrões, como mostrados na Figura 3.1.




Figura 3.1: Etapas da metodologia

3.1 Aquisição de imagens

Na primeira etapa desta pesquisa buscou-se adquirir as imagens que seriam utilizadas para validar a metodologia proposta. As imagens foram adquiridas através de uma base pública que contém mais de 60 mil imagens provenientes de exames de câncer de pele. Essa base encontra-se disponível na internet em The International Skin Imaging Collaboration (ISIC) (ISIC, 2020). Das 60 mil imagens disponíveis foi selecionado de forma aleatória um subconjunto de 2284 imagens, sendo 1200 de não melanomas e 1084 de melanomas.

Os 2284 casos foram segmentados conforme a abordagem em (BRAZ, 2008), onde, baseado em marcações feitas por especialistas, foram extraídos os bounding boxes, retângulo envolvente mínimo, sobre as regiões que apresentavam os possíveis melanomas, buscando focar no objetivo deste trabalho, já citado na Seção 1.1. O conjunto com as 2284 ROIs será usado para validar a metodologia proposta.

3.2 Pré-processamento

Nesta etapa busca-se melhorar a qualidade da imagem que contém as ROIs. As imagens oriundas de exames médicos, quando convertidas para o nível de cinza, apresentam poucos pixels com valores altos, ou seja, há a necessidade de reduzir o contraste delas em relação ao fundo das ROIs.

Para obter essa melhora no contraste utiliza-se o realce logaritmico conforme explicado na Seção 2.2. A constante C da Equação 2.1, que permite delimitar os novos valores calculados entre 0 e a intensidade máxima encontrada na imagem, foi definida como sendo 105,18, esse valor resulta do fato das ROIs possuírem 8 bits por pixel, o que permite que sua intensidade varie de 0 a 255.




Figura 3.2: Aplicação do realce logaritmico.

A Figura 3.2 mostra uma imagem antes de sua conversão para os níveis de cinza (a), o histograma da ROI antes da aplicação do realce logaritmico (b), e depois da sua aplicação (c).

3.3 Representação da Imagem

Aqui o objetivo é representar a ROI de forma que seu estudo não seja baseado nas intensidades dos pixels isolados, mas sim no relacionamento deste com seus vizinhos (GONZALEZ; WOODS, 1992). A abordagem proposta é descrita na Figura 3.3.

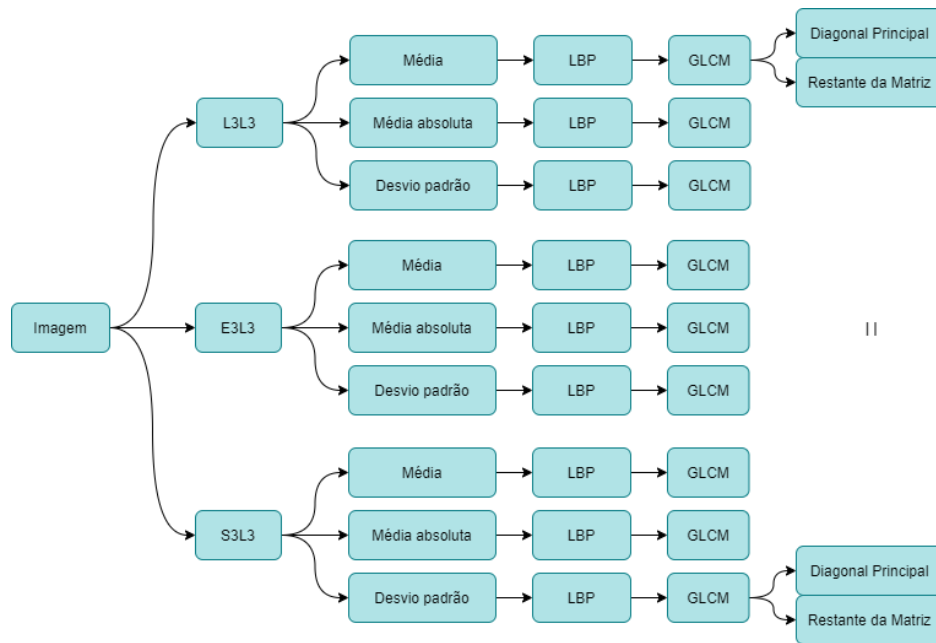


Figura 3.3: Representação da imagem.

A Figura 3.3 mostra que sobre cada imagem de entrada serão aplicadas três máscaras de Laws, sendo elas: L3L3, E3L3, S3L3. O objetivo é gerar máscaras que usem o filtro L3, já que ele é capaz de realçar os níveis de cinza. Sua combinação com o filtro E3 permite obter um realce em níveis de cinza presentes em bordas e sua combinação com o S3 permite realçar os níveis de cinza em regiões com manchas.

As máscaras geradas pelo filtro L3 são responsáveis pelo aumento na intensidade em todas as regiões da ROI, o que não o torna eficiente quando se busca modificar apenas regiões importantes para a textura. Por outro lado, quando combinado com outros filtros (como o E3 e S3) as máscaras geradas se tornam capazes de efetuar mudanças em uma região em especial, determinada pelo segundo filtro.

3 x 3	L3
L3	L3L3
E3	E3L3
S3	S3L3

Tabela 3.1: Máscaras geradas.

Para cada máscara gerada (Tabela 3.1) foram usados os três filtros propostos

na segunda etapa de geração da Medida de Textura de Energia de Laws (LTEM), como explicado na Seção 2.3; o da Média, da Média Absoluta e o do Desvio Padrão; todos com vizinhança 5×5 . Isso implica que para cada máscara usada eram geradas 3 novas ROIs. Como houve a implementação de 3 máscaras de tamanho 3×3 , para cada ROI de entrada eram geradas 9 novas ROIs de saída (3 máscaras \times 3 suavizações = 9 ROIs).

Dada a habilidade das máscaras de Laws de realçar regiões específicas de uma dada ROI, faz-se uso da LTEM para aguçar as principais regiões da ROI que apresentam informações relativas à textura (como bordas, erupções cutâneas, sobreposições de bordas, etc.), tornando-as mais relevantes quando for medido o Local Binary Pattern, permitindo assim que haja um melhor aproveitamento das informações presentes.

Como este trabalho busca classificar melanomas e a técnica da LTEM pode ser, dependendo da combinação dos filtros, voltada para a análise da textura através das bordas, do perímetro, das ondas, etc. presentes nas imagens, far-se-á uso exclusivo das três possíveis máscaras geradas pelo filtro L3 (focado no realce dos níveis de cinza), sem levar-se em conta as outras combinações possíveis, buscando assim melhorar o desempenho da metodologia na classificação dos melanomas.

Após a geração da LTEM foi feita a representação da imagem através de sua textura usando o Local Binary Patterns (LBP) com janela 3×3 , com o intuito de neste passo levar em conta os relacionamentos dos pixels com sua vizinhança.

Por fim foi criada a matriz GLCM para analisar os pares de LBP gerados, isso permite que os pares de LBP sejam armazenados levando em conta pares vizinhos localizados em direções e distâncias diferentes.

3.4 Extração de características

Buscando extrair as medidas descritivas que possuem informações sobre a textura das imagens para geração do vetor de características, fez-se uso de uma adaptação do conceito de índice de diversidade como explicado na sequência.

3.4.1 Índice de Diversidade de Shannon

Nesta pesquisa foi escolhido o Índice de Diversidade de Shannon para realizar a abordagem da extração dos descritores das imagens. A escolha decorre do fato de que o Índice de Shannon não requer o conhecimento prévio de toda a distribuição da população de espécies para ser calculado (SHANNON; WEAVER, 1949).

Para a utilização do Índice, definiu-se a comunidade como sendo os elementos internos da matriz de co-ocorrência e as espécies sendo formadas pelos valores destes elementos.

Sobre as matrizes GLCM foram aplicadas 6 quantizações gerando comunidades diferentes, uma com 256, outra com 128, 64, 32, 16 e por fim uma com 8 espécies. Sobre estas 6 comunidades expressas em forma de matriz de co-ocorrência foi extraído o Índice de Diversidade de Shannon em duas abordagens diferentes:

1. Analisando os pares de LBPs (i, j) , com $i = j$ com uma distância d e ângulo θ , ou seja, analisando somente a diagonal principal da matriz de co-ocorrência, como exemplificado na Figura 3.4 (c).
2. Analisando os pares de LBPs (i, j) , com $i \neq j$ com uma distância d e ângulo θ , ou seja, analisando todas as posições da matriz com exceção das pertencentes à diagonal principal, como exemplificado na Figura 3.4 (d).




Figura 3.4: Abordagem usada na GLCM. Fonte: (ROCHA, 2014)

Para exemplificar as duas abordagens um exemplo é mostrado na Figura 3.4. Nela é possível ver em (a) uma ROI de tamanho 5x5 que exemplifica a distribuição dos pixels em uma imagem. Em (b) está a matriz de co-ocorrência gerada quando $d=1$ e $\theta=0$. Por sua vez, (c) mostra como é a abordagem que leva em conta apenas os valores da diagonal principal, onde $i = j$. E, por fim, (d) exemplifica como é a abordagem quando se leva em conta apenas os valores que não estão presentes na diagonal principal, ou seja, quando $i \neq j$.

Foram usados em d as distâncias 1, 2, 3, 4 e 5. Para o ângulo θ foram usados 0° , 45° , 90° e 135° . Combinando todas implementações mais as 6 quantizações, o vetor de características apresentará 120 descritores extraídos por imagem (5 d 's x 4 θ 's x 6 quantizações = 120 descritores).

Lembrando que na representação das imagens (Seção 3.3) para cada máscara gerada foram implementados os três Filtros de Suavização, o que resulta em três imagens de saída para cada imagem de entrada. Nesta abordagem, cada imagem de saída será tratada como sendo uma imagem independente, tendo cada uma delas sua própria representação e vetor de características.

3.5 Reconhecimento de Padrões

Para efetuar o levantamento dos resultados é necessário realizar o reconhecimento dos vetores de características gerados. Neste trabalho foi usado a Máquina de Vetores de Suporte (MVS) (CHANG, 2011) como em Braz (2008) seguindo os passos explanados a seguir.

3.5.1 Máquina de Vetores de Suport

A Figura 3.5 detalha a sequência de passos seguidos para efetuar o reconhecimento usando a MVS. Após a criação das características é usado o svm-scale para realizar uma normalização nos valores destas na faixa entre -1 e 1, visando facilitar a convergência do classificador e padronizar a distribuição de valores das variáveis (BRAZ, 2008).

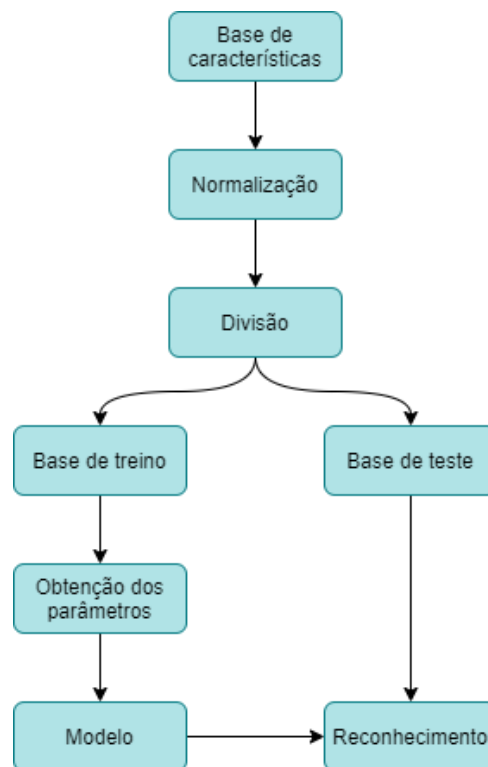


Figura 3.5: Passos do reconhecimento. Adaptação de (BRAZ, 2008)

Findado o processo de normalização, a base de características é dividida de forma aleatória em duas partes, respectivamente: uma para ser usada para o treino da MVS e a outra para ser usada como teste. As divisões foram 50/50, 60/40, 70/30 e 80/20.

Os testes são efetuados 5 vezes para cada proporção usada, a divisão dessas proporções é feita de forma aleatória buscando mostrar a capacidade da metodologia em representar as imagens, mantendo em todas as características iniciais e realçando suas propriedades.

Sobre os 5 testes realizados é obtida a média dos resultados da acurácia, da sensibilidade e da especificidade. Também é feito a análise do desvio padrão nesses 5 testes, para mostrar a discrepância da qualidade do reconhecedor ao classificar as características geradas.

Fazendo uso do `grid.py` é possível, por meio da validação cruzada, estimar quais os melhores parâmetros (custo C , grau de complexidade de mapeamento γ , etc.) para a obtenção do melhor modelo de treino para uso no reconhecimento. A estimativa desse parâmetros é feita levando em conta aqueles que retornam o melhor percentual de acertos sobre a base de amostra de treino e teste.

Por fim, após os modelos gerados e o MVS treinado, o MVS é alimentado com a Base de Teste e inicia-se a etapa do reconhecimento. No reconhecimento cada características é distribuída pelo plano do MVS e o hiperplano gerado durante o treinamento é usado para classificá-las.

3.5.2 Validação dos Resultados

Para realizar a validação dos resultados foi feito o cálculo da média da Acurácia, média da Sensibilidade e média da Especificidade juntamente com seus respectivos desvio padrão, levando em conta os 5 reconhecimentos de cada proporção utilizada, conforme explicado na Seção 2.8. O cálculo dessas estatísticas é obtido sobre os arquivos de saída da MVS após o término da classificação das características.

3.6 Considerações Finais

Neste capítulo foi explanada a metodologia proposta por este trabalho para se alcançar a discriminação de melanomas e não melanomas por meio das características presentes na textura das imagens. A seguir serão mostrados os resultados obtidos após a realização

do reconhecimento sobre as características geradas neste capítulo, os resultados serão expostos em duas partes, a primeira com os obtidos no uso da diagonal principal da matriz de co-ocorrência e a segunda com o uso do restante da matriz de co-ocorrência para a extração das características.

4 Resultados

Neste capítulo serão apresentados e detalhados os resultados obtidos ao aplicar a metodologia proposta. Os resultados estão divididos conforme as abordagens usadas.

Como explicado na Metodologia Proposta, para cada abordagem de teste foram realizadas 5 repetições. O resultado foi calculado sobre a média das 5 acurácias, sensibilidade e especificidade encontradas. A realização de mais de um reconhecimento por base de amostras permite que também seja levado em conta durante a validação dos resultados o desvio padrão da acurácia, sensibilidade e da especificidade.

Como tratado na Seção 3.4.1, duas abordagens diferentes foram tomadas em relação a extração das características. Na primeira levou-se em conta somente os pares de LBP com valores iguais, o que nos permite a análise de regiões das imagens onde há a predominância de um tipo de relacionamento, comumente encontrado em não-melanomas.

Na segunda abordagem foi feita a extração das características sobre toda a matriz de co-ocorrência com exceção da sua diagonal principal, ou seja, foram levados em conta somente os pares de LBP que tinham valores diferentes.

Isso permite analisar as principais regiões presentes nos melanomas, já que eles apresentam bordas internas e várias outras sobreposições de pele. Essas regiões abrangem os relacionamentos das bordas, as quais são fundamentais e responsáveis por distinguir tais imagens.

Nas Tabelas 4.1, 4.2 e 4.3 são apresentados os resultados da primeira abordagem; e nas Tabelas 4.4, 4.5 e 4.6 são mostrados os resultados colhidos na abordagem dois.

4.0.1 Abordagem 1

A abordagem 1 leva em conta a extração das características apenas na diagonal principal da matriz de co-ocorrência (pares de LBP com valores iguais), tendo um total de 120 características extraídas por imagem (Seção 3.3), e considerando todos os 3 filtros de suavização propostos por Laws. Nessa configuração os melhores valores obtidos foram

aqueles onde as máscaras usadas foram geradas a partir dos filtros capazes de realçar os níveis de cinza (L3) e as bordas (E3), por outro lado, os resultados menores vieram de máscaras geradas pelo filtro de realce das manchas (S3).

Para as máscaras geradas pelo filtro L3, a que teve o melhor resultado foi a L3L3 (Tabela 4.1), alcançando uma média de acurácia de 91,86%, uma sensibilidade de 83,41% e uma especificidade de 99,50%, na proporção 80/20 com o filtro de suavização da LTEM sendo o do desvio padrão.

As geradas pelo filtro E3 e L3 (Tabela 4.2) se mostraram semelhantes à máscara anterior, com a E3L3 chegando a uma média de acurácia igual a 90,37%, com uma sensibilidade de 81,29% e 98,58% de especificidade também na proporção 80/20, mas desta vez com a suavização realizada pelo filtro da média.

Tabela 4.1: Resultados da máscara L3L3 na abordagem 1 (diagonal principal)

Filtro	Grid	Média Acurácia	Média Sensibilidade	Média Especificidade
Média Absoluta	50/50	84,64 ± 0,01	73,06 ± 0,02	95,10 ± 0,01
	60/40	86,67 ± 0,01	78,53 ± 0,02	94,04 ± 0,00
	70/30	87,26 ± 0,01	80,49 ± 0,01	93,39 ± 0,01
	80/20	89,58 ± 0,02	80,74 ± 0,04	97,58 ± 0,01
Desvio Padrão	50/50	81,84 ± 0,02	68,67 ± 0,03	93,73 ± 0,02
	60/40	84,42 ± 0,01	73,78 ± 0,02	94,04 ± 0,01
	70/30	88,45 ± 0,01	81,47 ± 0,03	94,78 ± 0,01
	80/20	91,86 ± 0,01	83,41 ± 0,02	99,50 ± 0,00
Média	50/50	85,32 ± 0,01	74,65 ± 0,02	94,97 ± 0,00
	60/40	85,97 ± 0,01	77,70 ± 0,03	93,46 ± 0,01
	70/30	86,59 ± 0,02	78,53 ± 0,03	93,89 ± 0,00
	80/20	90,02 ± 0,03	81,57 ± 0,06	97,67 ± 0,01

Por outro lado, a máscara gerada pelo filtro S3 obteve resultados inferiores aos anteriores. O melhor valor alcançado foi na proporção 80/20 com uma acurácia de 89,98%, uma sensibilidade de 81,29% e 97,83% de especificidade. Esses resultados são mostrados na Tabela 4.3.

A explicação para a grande diferença de percentual entre a sensibilidade e a especificidade se dá pelo fato de que as imagens de não melanomas apresentam uma superfície mais regular, ou seja, têm um padrão que pode facilmente ser assimilado e classificado. Os melanomas por sua vez não apresentam superfície regular, pelo contrário, sua formação dá-se em sobrepor-se e crescer de forma desorganizada, o que torna a imagem

Tabela 4.2: Resultados da máscara E3L3 na abordagem 1 (diagonal principal)

Filtro	Grid	Média Acurácia		Média Sensibilidade		Média Especificidade	
Média Absoluta	50/50	87,26	± 0,01	79,33	± 0,01	94,44	± 0,01
	60/40	90,94	± 0,01	82,40	± 0,02	98,67	± 0,00
	70/30	87,26	± 0,01	79,33	± 0,01	94,44	± 0,01
	80/20	90,94	± 0,01	82,40	± 0,02	98,67	± 0,00
Desvio Padrão	50/50	84,17	± 0,01	72,58	± 0,02	94,63	± 0,00
	60/40	83,63	± 0,01	72,17	± 0,02	94,00	± 0,00
	70/30	84,49	± 0,01	75,40	± 0,03	92,72	± 0,00
	80/20	88,62	± 0,01	79,26	± 0,03	97,08	± 0,00
Média	50/50	82,54	± 0,00	70,11	± 0,02	93,77	± 0,01
	60/40	85,62	± 0,02	75,76	± 0,03	94,54	± 0,02
	70/30	86,15	± 0,02	77,55	± 0,04	93,94	± 0,01
	80/20	90,37	± 0,03	81,29	± 0,06	98,58	± 0,00

mais difícil de ser classificada.

Tabela 4.3: Resultados da máscara S3L3 na abordagem 1 (diagonal principal)

Filtro	Grid	Média Acurácia		Média Sensibilidade		Média Especificidade	
Média Absoluta	50/50	83,10	± 0,01	69,59	± 0,02	95,30	± 0,01
	60/40	84,77	± 0,01	73,82	± 0,02	94,67	± 0,01
	70/30	86,27	± 0,02	78,04	± 0,05	93,72	± 0,01
	80/20	87,70	± 0,02	76,96	± 0,04	97,42	± 0,00
Desvio Padrão	50/50	82,82	± 0,01	70,52	± 0,03	93,93	± 0,01
	60/40	83,50	± 0,02	72,67	± 0,04	93,29	± 0,01
	70/30	84,90	± 0,01	76,93	± 0,03	92,11	± 0,01
	80/20	88,62	± 0,01	77,42	± 0,03	98,75	± 0,01
Média	50/50	81,21	± 0,02	68,52	± 0,03	92,67	± 0,02
	60/40	86,08	± 0,04	76,68	± 0,07	94,58	± 0,01
	70/30	86,76	± 0,02	79,57	± 0,04	93,28	± 0,01
	80/20	89,98	± 0,01	81,29	± 0,02	97,83	± 0,01

4.0.2 Abordagem 2

Na segunda abordagem usada, onde foi feito a extração das características em toda a matriz de co-ocorrência com exceção dos pontos onde os pares de LBPs eram iguais, também foi gerado um vetor com 120 características para cada imagem. Nesta abordagem obteve-se o mesmo padrão de resultados.

Novamente as máscaras geradas com uso do filtro de aguçamento dos níveis de cinza (L3) apresentaram os melhores resultados. A máscara L3L3 na proporção 80/20

chegou a uma acurácia de 90,68%, com uma sensibilidade de 82,49% e 98,08% de especificidade. Já as máscaras geradas a partir do filtro S3 mostraram-se novamente com os resultados onde a diferença entre a especificidade e sensibilidade foram maiores, como na proporção 80/20 da máscara S3L3 com acurácia de 89,93%, uma sensibilidade de 81,29% e uma especificidade de 97,75%.

O filtro E3 gerou a máscara que se manteve com resultados acima das do S3 e abaixo das do L3, seu melhor desempenho foi colhido na proporção 80/20 (máscara E3L3 na Tabela 4.5) onde a acurácia chegou a 90,11%, a sensibilidade a 81,66% e a especificidade a 97,75%.

Tabela 4.4: Resultados da máscara L3L3 na abordagem 2 (matriz interna)

Filtro	Grid	Média		Média		Média	
		Acurácia		Sensibilidade		Especificidade	
Média Absoluta	50/50	86,74	± 0,01	79,23	± 0,02	93,53	± 0,01
	60/40	86,48	± 0,01	78,34	± 0,01	93,83	± 0,01
	70/30	86,47	± 0,01	80,06	± 0,02	92,28	± 0,00
	80/20	88,27	± 0,01	79,45	± 0,01	96,25	± 0,02
Desvio Padrão	50/50	85,69	± 0,01	75,31	± 0,02	95,07	± 0,01
	60/40	87,72	± 0,02	78,76	± 0,03	95,83	± 0,00
	70/30	89,15	± 0,01	83,62	± 0,03	94,17	± 0,00
	80/20	90,68	± 0,03	82,49	± 0,06	98,08	± 0,01
Média	50/50	85,66	± 0,01	76,94	± 0,02	93,53	± 0,01
	60/40	87,66	± 0,01	81,34	± 0,02	93,38	± 0,01
	70/30	88,22	± 0,01	83,37	± 0,02	92,61	± 0,01
	80/20	90,15	± 0,01	82,76	± 0,03	96,83	± 0,02

Tabela 4.5: Resultados da máscara E3L3 na abordagem 2 (matriz interna)

Filtro	Grid	Média		Média		Média	
		Acurácia		Sensibilidade		Especificidade	
Média Absoluta	50/50	87,64	± 0,01	81,72	± 0,02	93,00	± 0,00
	60/40	89,67	± 0,02	82,12	± 0,03	96,50	± 0,00
	70/30	87,64	± 0,01	81,72	± 0,02	93,00	± 0,00
	80/20	89,67	± 0,02	82,12	± 0,03	96,50	± 0,00
Desvio Padrão	50/50	80,96	± 0,01	71,40	± 0,03	89,60	± 0,02
	60/40	83,44	± 0,02	75,07	± 0,03	91,00	± 0,01
	70/30	82,57	± 0,02	74,79	± 0,03	89,61	± 0,01
	80/20	86,87	± 0,02	79,63	± 0,04	93,42	± 0,02
Média	50/50	83,24	± 0,02	72,80	± 0,05	92,67	± 0,02
	60/40	86,37	± 0,01	78,80	± 0,03	93,21	± 0,00
	70/30	87,20	± 0,01	81,53	± 0,03	92,33	± 0,01
	80/20	90,11	± 0,02	81,66	± 0,05	97,75	± 0,01

Tabela 4.6: Resultados da máscara S3L3 na abordagem 2 (matriz interna)

Filtro	Grid	Média Acurácia		Média Sensibilidade		Média Especificidade	
Média Absoluta	50/50	83,22	± 0,01	69,85	± 0,04	95,30	± 0,01
	60/40	84,22	± 0,01	73,27	± 0,01	94,12	± 0,02
	70/30	85,98	± 0,02	77,98	± 0,05	93,22	± 0,01
	80/20	89,02	± 0,03	79,45	± 0,08	97,67	± 0,00
Desvio Padrão	50/50	81,84	± 0,02	68,67	± 0,03	93,73	± 0,02
	60/40	84,42	± 0,01	73,78	± 0,02	94,04	± 0,01
	70/30	83,73	± 0,02	74,60	± 0,04	92,00	± 0,02
	80/20	89,93	± 0,02	81,29	± 0,04	97,75	± 0,02
Média	50/50	81,86	± 0,03	69,96	± 0,03	92,60	± 0,04
	60/40	86,89	± 0,01	76,91	± 0,02	95,92	± 0,01
	70/30	86,79	± 0,02	78,77	± 0,04	94,06	± 0,01
	80/20	89,54	± 0,02	80,55	± 0,04	97,67	± 0,01

A abordagem 2 mostrou melhoria em relação à diminuição da diferença entre a sensibilidade e a especificidade à medida que as regiões de bordas e transições presentes nas imagens foram considerando os pares de LBP com valores diferentes. Isso trouxe uma melhora significativa para a média da sensibilidade, confirmando que a classificação de melanomas fazendo uso da textura depende diretamente da avaliação do contorno dos agrupamentos das células.

4.1 Discussão

Para os resultados obtidos, os oriundos da abordagem 2 foram os que apresentaram os melhores desempenhos, mostrando-se capazes de manter as diferenças entre os melanomas e não melanomas, sendo o primeiro mais difícil de classificar. Como a segunda abordagem analisa os pares de LBP com valores diferentes, ela se sobressai em comparação com a primeira porque contém as informações sobre os relacionamentos dos LBPs gerados sobre os pixels presentes em bordas e outras transições presentes nas imagens. Tais posições contêm mais informações relacionadas à textura, que por sua vez considera o agrupamento desordenado dos conjuntos de células.

Já na abordagem 1, que usa os pares de LBP iguais, os relacionamentos mais tratados são aqueles que apresentam uniformidade na distribuição das células, sendo normalmente provenientes de imagens de exames com resultados negativos.

Como efetuar um aumento nas intensidades dos níveis de cinza não interfere nos relacionamentos entre os pixels, realizar a extração das características usando toda a matriz de co-ocorrência, e não somente a sua diagonal principal, mostrou-se mais plausível, mesmo com a diferença entre as duas abordagens não sendo tão grande.

A diferença entre o percentual da sensibilidade e da especificidade se deu pelo fato de que ao classificar os melanomas fatores como o crescimento desordenado das bordas, a assimetria das lesões e o diâmetro dos melanomas devem ser considerados. Como a textura analisa esses fatores apenas quando eles se encontram em proporções menores dentro das lesões, a sua classificação não foi tão efetiva quanto os não melanomas, já que estes apresentam padrões que são mais facilmente classificados.

Essa diferença pode ser melhorada desde que a análise da textura seja aliada à análise do contorno das lesões e à análise do diâmetro dos melanomas, melhorando as características extraídas e possibilitando mais descritores que analisem todas as possíveis características presentes nos melanomas.

Esta pesquisa procurou contribuir para o uso exclusivo da textura no diagnóstico de melanomas e não melanomas fazendo uso das máscaras de Laws para realçar regiões importantes para o estudo da textura. Ademais, a metodologia proposta se mostrou promissora, dada a média de acurácia alcançada estar na faixa de 90% e o desvio padrão das médias ter sido baixo.

Quando os resultados são analisados do ponto de vista dos filtros que compõem as máscaras, fica visível a necessidade do realce dos pixels em regiões importantes para o relacionamento destes. As máscaras geradas a partir do filtro L3 e do E3, que são respectivamente responsáveis pelo realce dos níveis de cinza e das bordas presentes nas lesões, foram as que mais efetuaram melhorias nos resultados. Pode-se concluir sobre as máscaras:

- L3L3, realça as intensidades dos pixels presentes na imagem.
- E3L3, realça os níveis de cinza presentes nas bordas da imagem.
- S3L3, realça os níveis de cinza presentes nas manchas presentes na imagem.

Comparar a metodologia proposta com outros trabalhos relacionados não é uma

tarefa simples, uma vez que o trabalho proposto possui de diferente a base de imagens, a quantidade de amostras e a abordagem usada.

Ao comparar com os trabalhos de Abdul-Wadood, George e Rasheed (2014), Sheha et al. (2012) e Masood, Al-Jumaily e Anam (2014) é possível observar que, mesmo com valores de acurácia próximos, houve um diferencial no valor das especificidades, possivelmente decorrente do número de amostras usadas, posto que nos três trabalhos a base de imagens utilizada é na ordem de 8 a 28 vezes menor que a desta pesquisa. Em experimentos realizados foi observado que quanto menor a base de imagens menor é a heterogeneidade das lesões e mais fácil é a classificação dos melanomas, o que pode explicar a diferença das especificidades.

Quando comparado com as pesquisas que não fazem uso da análise de textura é possível ver que os resultados deste trabalho são promissores. Tanto Boaro et al. (2020) quanto (NIDA et al., 2019) ao fazerem uso de redes neurais obtiveram acurácia, especificidade e sensibilidade acima dos 90%. A robustez desses métodos é dependente das características que foram extraídas, já que fazem análise sobre contornos de borda, assimetria das lesões, mudanças de cores, etc.

Essas características são as mesmas levadas em conta pelos especialistas durante o diagnóstico. É comum que as lesões apresentem bordas irregulares, que o diâmetro das lesões seja maior, etc.; essas características são relacionadas à forma que o melanoma se apresenta na pele e não são propriamente analisadas quando usado apenas o estudo da textura.

Por outro lado, (BISLA et al., 2019) alcançou uma acurácia de 81% usando técnicas para purificação dos dados, permitindo a remoção de pelos e outros ruídos que pudessem interferir na classificação dos melanomas. Seus resultados, entretanto, são inferiores ao deste trabalho porque a metodologia proposta busca classificar três tipos de câncer de pele, e não apenas os melanomas.

A Tabela 4.7 elucidada o comparativo entre os trabalhos citados. Em azul são mostrados os trabalhos que utilizam apenas a análise de textura e em cinza são apresentados os que fazem uso de outras abordagens.

Este capítulo apresentou os resultados obtidos em ambas as abordagens propos-

Tabela 4.7: Comparação com trabalhos relacionados

Trabalho	Base	ROIs	Acurácia %	Sensibilidade %	Especificidade %
(SHEHA et al., 2012)	D-Atlas	102	92,0	92,3	91,6
(ABDUL-WADOOD; GEORGE; RASHEED,2014)	Própria	80	92,5	92,3	-
(MASOOD; AL-JUMAILY; ANAM, 2014)	Própria	270	90,0	91,0	89,0
Metodologia proposta (abordagem 2)	ISIC	2284	91,9	83,4	99,5
(BOARO et al., 2019)	ISIC	4018	92,6	90,9	92,8
(NIDA et al., 2019)	ISIC	1276	94,8	97,8	94,2
(BISLA et al., 2019)	Várias	959	81,6	-	-

tas na metodologia, explicando o motivo dos resultados e comparando-os com alguns dos trabalhos disponíveis na literatura. Em seguida será apresentada a conclusão desta pesquisa.

5 Conclusão

O estudo de imagens de exames de câncer de pele através do uso exclusivo da textura é importante para a classificação melanomas e não melanomas, contribuindo para o rápido e eficiente diagnóstico do câncer de pele. Porém, encontra-se uma dificuldade graças a necessidade de realizar uma melhoria na forma de tratar os relacionamentos entre os pixels das imagens analisadas, o que dificulta o estudo da textura. Tais dificuldades podem ser reduzidas ao se fazer uso de uma abordagem estatística.

Para isso, inicialmente foi feita uma nova representação das imagens, buscando deixar mais explícito os relacionamentos existentes entre os pixels, já que esses relacionamentos possibilitam realizar um estudo mais aprimorado sobre a textura de uma imagem.

Essa nova representação foi resultado da combinação de técnicas capazes de aprimorar propriedades importantes, tais como: a LTEM, importante para o relacionamento dos pixels; o LBP, que contribui para relacionar um pixel com seus vizinhos; e a GLCM, usada para uma melhor manipulação dos relacionamentos.

Após seguir a metodologia proposta pela pesquisa, observou-se que quando usadas máscaras que podem aprimorar os relacionamentos dos pixels é possível obter bons resultados, como os da máscara L3L3 que chegou a uma média de acurácia de 90,68%, tendo suas características extraídas da matriz de co-ocorrência nos pontos onde os pares de LBP apresentavam valores diferentes.

Também é possível notar que quando a máscara da LTEM aplicada é gerada com o uso de um filtro que realça principalmente os valores das manchas presentes nas ROIs (filtro S3), as quais não são comuns em melanomas, a detecção dos melanomas é menos efetiva, chegando a uma acurácia de 89,98%.

Assim, para a obtenção de máscaras capazes de aprimorar e realçar os relacionamentos dos pixels, é necessário a aplicação de filtros que sejam voltados para características presentes nas regiões importantes de lesões presentes nas imagens, como os filtros L3 e E3 que realçam, respectivamente, as intensidades dos níveis de cinza e as bordas encontradas nas ROIs.

Por fim, esta pesquisa buscou contribuir para a qualidade do reconhecimento de imagens de exames de câncer de pele fazendo uso unicamente da textura presente nas imagens. Contribuindo também como forma de exposição do uso das máscaras de Laws para tratar a textura em imagens com melanomas.

5.1 Trabalhos Futuros

Algumas melhorias podem ser realizadas sobre esta pesquisa, principalmente as que dizem respeito a redução do diferencial entre a média de especificidade e sensibilidade. Como explicado anteriormente, essa diferença decorre do fato de que o uso exclusivo da textura não permite que sejam levados em conta fatores importantes para a classificação dos melanomas, bem como assimetria da borda, diâmetro das lesões, etc. Partindo desse ponto, os possíveis trabalhos futuros podem:

- Combinar técnicas de análise de bordas junto ao estudo da textura;
- Usar outros filtros para a geração das máscaras de Laws, ampliando o kernel para 5x5 e 7x7, permitindo que mais informações sejam levadas em conta durante o realce das regiões;
- Usar variações de LBP que permitam que uma maior vizinhança seja levada em conta ao calcular os relacionamentos, bem como o LBP circular e o Completed Local Binary Pattern; e
- Testar a metodologia proposta com outras bases de imagens.

Referências

- ABDUL-WADOOD, D. N.; GEORGE, L. E.; RASHEED, N. A. Diagnosis of skin cancer using image texture analysis. *International Journal of Scientific & Engineering Research*, v. 5, n. 6, p. 155, 2014.
- ACS. *Key Statistics for Melanoma Skin Cancer*. 2020. Disponível em: <<https://www.cancer.org/cancer/melanoma-skin-cancer/about/key-statistics.html>>. Acesso em: 28 nov. 2020.
- BISLA, D. et al. Towards automated melanoma detection with deep learning: Data purification and augmentation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. [S.l.: s.n.], 2019. p. 0–0.
- BLAND, M. Sampling and observational studies. *Introduction to Medical Statistics*. New York: Oxford University Press Inc, p. 26–46, 2000.
- BOARO, J. M. et al. Hybrid capsule network architecture estimation for melanoma detection. In: IEEE. *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*. [S.l.], 2020. p. 93–98.
- BRAZ, G. *Classificação de regiões de mamografias em massa e não massa usando estatística espacial e máquina de vetores de suporte*. Dissertação (Mestrado) — Dissertação (Mestrado em Engenharia de Eletricidade), Centro de Ciências . . . , 2008.
- CHANG, C.-C. "libsvm: a library for support vector machines," *acm transactions on intelligent systems and technology*, 2: 27: 1–27: 27, 2011. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, v. 2, 2011.
- FILHO, O. M.; NETO, H. V. *Processamento digital de imagens*. [S.l.]: Brasport, 1999.
- FRANGE, V. M. N.; ARRUDA, L. H. F.; DALDON, P. É. C. Dermatoscopia: importância para a prática clínica. *Revista de Ciências Médicas*, v. 18, n. 4, 2012.
- GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. *Digital image processing using MATLAB*. [S.l.]: Pearson Education India, 2010.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, Ieee, n. 6, p. 610–621, 1973.
- INCA. *câncer de pele melanona*. 2020. Disponível em: <<https://www.inca.gov.br/tipos-de-cancer/cancer-de-pele-melanoma>>. Acesso em: 28 nov. 2020.
- ISIC. *The International Skin Imaging Collaboration*. 2020. Disponível em: <<https://www.isic-archive.com/#!/topWithHeader/onlyHeaderTop/gallery>>. Acesso em: 28 nov. 2020.
- JAIN, S. et al. Computer aided melanoma skin cancer detection using image processing. *Procedia Computer Science*, Elsevier, v. 48, p. 735–740, 2015.

- JERANT, A. F. et al. Early detection and treatment of skin cancer. *American family physician*, v. 62, n. 2, p. 357–368, 2000.
- LAWS, K. Textured image segmentation [ph. d. dissertation]. *Los Angeles, CA: University of Southern California*, 1980.
- LEMAÎTRE, G.; RODOJEVIC, M. Texture segmentation: Co-occurrence matrix and laws' texture masks methods. 2007.
- MAGURRAN, A. E. *Medindo a diversidade biológica*. [S.l.: s.n.], 2004. v. 261.
- MAIA, W. H. *Uma Proposta Para Detecção Automática de Câncer de Pele Baseando-se Em Características de Forma, Cor E Textura*. [S.l.]: UFERSA, 2015.
- MASOOD, A.; AL-JUMAILY, A.; ANAM, K. Texture analysis based automated decision support system for classification of skin cancer using sa-svm. In: SPRINGER. *International Conference on Neural Information Processing*. [S.l.], 2014. p. 101–109.
- 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.
- NIDA, N. et al. Melanoma lesion detection and segmentation using deep region based convolutional neural network and fuzzy c-means clustering. *International journal of medical informatics*, Elsevier, v. 124, p. 37–48, 2019.
- OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, Elsevier, v. 29, n. 1, p. 51–59, 1996.
- PEDRINI, H.; SCHWARTZ, W. R. *Análise de imagens digitais: princípios, algoritmos e aplicações*. [S.l.]: Thomson Learning, 2008.
- ROCHA, S. V. d. *Diferenciação do padrão de malignidade e benignidade de massas em imagens de mamografias usando padrões locais binários, geoestatística e índice de diversidade*. Tese (Doutorado), 2014.
- SANTOS, E. M. d. et al. Teoria e aplicação de support vector machines à aprendizagem e reconhecimento de objetos baseado na aparência. Universidade Federal de Campina Grande, 2002.
- SANTOS, V. K. D. Uma generalização da distribuição do índice de diversidade generalizado por good com aplicação em ciências agrárias. 2009.
- SHANNON, C.; WEAVER. The mathematical theory of communication. *The Mathematical Theory of Communication*. *EUA: University of Illinois Press, Urbana*, 1949.
- SHEHA, M. A. et al. Automatic detection of melanoma skin cancer using texture analysis. *International Journal of Computer Applications*, Citeseer, v. 42, n. 20, p. 22–26, 2012.
- VAPNIK, V. Statistical learning theory wiley-interscience. *New York*, v. 1, p. 624, 1998.