



UNIVERSIDADE FEDERAL DO MARANHÃO

Curso de Ciência da Computação

Lucas Bezerra Maia

**Diagnóstico de Melanoma através de HOG,  
função K de Ripley e Alpha-Shapes**

São Luís - MA

Janeiro - 2017

Lucas Bezerra Maia

# Diagnóstico de Melanoma através de HOG, função K de Ripley e Alpha-Shapes

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.

Curso de Ciência da Computação

UFMA

Orientador: Prof. Dr. Geraldo Braz Jr.

São Luís - MA

Janeiro - 2017

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

Bezerra Maia, Lucas.

Diagnóstico de Melanoma através de HOG, função K de Ripley e Alpha-Shapes / Lucas Bezerra Maia. - 2017.  
62 f.

Orientador(a): Geraldo Braz Junior.

Monografia (Graduação) - Curso de Ciência da Computação, Universidade Federal do Maranhão, São Luís - MA, 2017.

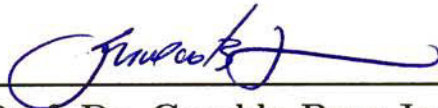
1. Alpha Shapes. 2. Diagnóstico. 3. Função K de Ripley. 4. HOG. 5. Melanoma. I. Braz Junior, Geraldo. II. Título.

Lucas Bezerra Maia

# Diagnóstico de Melanoma através de HOG, função K de Ripley e Alpha-Shapes

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.

Monografia Aprovada em 30 de Janeiro de 2017 São Luís - MA



---

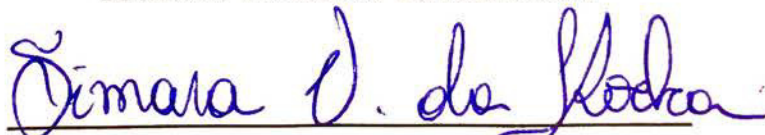
Prof. Dr. Geraldo Braz Jr.  
Orientador



---

Prof. Dr. João Dallyson Sousa de  
Almeida

Membro da Banca Examinadora



---

Prof.ª Dr.ª Simara Vieira da Rocha  
Membro da Banca Examinadora

São Luís - MA

Janeiro - 2017

# Agradecimentos

Agradeço ao apoio incondicional dos meus pais, oferecendo-me todas as condições necessárias, estando ao alcance deles ou não. Para eles guardo meu eterno amor e gratidão;

Ao meu orientador e amigo Geraldo Braz Junior, de onde veio inspiração e motivação, e sem o qual esse trabalho não seria possível;

À amiga de todas as horas, companheira e fiel porto seguro Elydillse Maria Botelho Lindoso;

A todos os meus amigos, em especial Roberto Matheus Pinheiro Pereira e Nigel da Silva Lima pelas lutas, glórias e farras compartilhadas;

A todos que participaram de forma direta e indireta dessa minha formação.

*"Existe uma grande diferença entre conhecer o caminho e trilhar o caminho."*

Morpheus, 1999

# Resumo

O melanoma é o tipo de câncer de pele mais letal quando comparado com os demais, porém os pacientes apresentam índices de recuperação elevados se a doença for descoberta em sua fase inicial. Seu diagnóstico prévio ainda apresenta um desafio para pessoas cujo acesso aos médicos especialistas é inviável. Diversas abordagens de detecção e diagnóstico automático vêm sendo exploradas por diferentes autores, usando técnicas de reconhecimento de padrões e aprendizado de máquina. Neste trabalho, é proposto um modelo para classificação automática de câncer de pele melanoma, por meio de um processo de treinamento supervisionado de máquinas de vetor de suporte, tendo como comparação as características extraídas pelos métodos de histogramas de gradientes orientados, análise espacial com função K de Ripley e análise geométrica de estruturas côncavas determinadas através de *Alpha-Shapes*. Os resultados obtidos são promissores devido às taxas de sensibilidades e precisão encontradas, principalmente usando o método de geometria côncava para extração de características.

**Palavras-chaves:** Melanoma, HOG, Função K de Ripley, Alpha Shapes, Diagnóstico.

# Abstract

Melanoma is the most lethal type of skin cancer compared to the others, however patients present high recovery rates when their illness is discovered in its primary stage. Several approaches to automatic detection and diagnosis have been explored by different authors, using pattern recognition and machine learning techniques. In this work, a model for automatic classification of melanoma skin cancer is proposed, through a supervised training process of support vector machines, comparing the characteristics extracted by Histogram of Oriented Gradients, spatial analysis with Ripley's K function and geometric analysis of concave structures determined through *Alpha-Shapes*. The results obtained are promising due to the sensitivity and precision rates found, mainly using the concave geometry method for extraction of characteristics.

**Keywords:** Melanoma, HOG, Ripley's K function, Alpha Shapes, Diagnosis.



# Lista de Figuras

Figura 1 – Representação espacial das taxas brutas de incidência de neoplasias malignas de pele a cada 100 mil homens/mulheres, estimadas para o ano de 2016, segundo Unidade de Federação. . . . .	15
Figura 2 – Exame dermatoscópico. . . . .	16
Figura 3 – Dermatoscopias mostrando a Regra ABCD. . . . .	22
Figura 4 – Passos fundamentais em processamento de imagens digitais. . . . .	23
Figura 5 – Representação de uma imagem digital. . . . .	24
Figura 6 – Superposição de matrizes para imagens coloridas (RGB). . . . .	25
Figura 7 – Representação do esquema de cores HSV. . . . .	25
Figura 8 – (a) Imagem de melanoma. (b) Canal vermelho da imagem e (c) Histograma correspondente. . . . .	26
Figura 9 – (a) DFA. (b) Histograma equalizado e (c) Imagem resultante do canal. . . . .	27
Figura 10 – (a) Canal vermelho e (b) realce logarítmico. . . . .	28
Figura 11 – Ilustração dos vizinhos de um determinado pixel. . . . .	29
Figura 12 – Configuração de extração de HOGs em uma imagem. . . . .	30
Figura 13 – Distribuição de magnitudes de gradientes. . . . .	30
Figura 14 – Análise de Ripley com área circular de raio $r$ . . . . .	32
Figura 15 – Alpha Shapes de um conjunto de pontos em um plano. . . . .	34
Figura 16 – À esquerda, $k$ -simplexo $\alpha$ -exposto. À direita, $k$ -simplexo não $\alpha$ -exposto . . . . .	35
Figura 17 – Representação de um $complexo-\alpha$ a partir dos triângulos de $TD(S)$ . . . . .	36
Figura 18 – Hiperplano de separação para padrões lineares. . . . .	37
Figura 19 – Fluxograma do Modelo de Classificação . . . . .	41
Figura 20 – Imagem da base ISIC: (a) Dermatoscopia e (b) máscara binária. . . . .	42
Figura 21 – Preparação: (a) Dermatoscopia (b) máscara binária e (c) região de interesse. . . . .	43
Figura 22 – Minimização de ruídos: (a) Original e (b) após filtro gaussiano. . . . .	43
Figura 23 – Disposição de blocos nas imagens. . . . .	45
Figura 24 – Função K de Ripley: (a) Área circular e (b) Área em anel. . . . .	46
Figura 25 – Descrição de forma em lesões de pele. . . . .	47
Figura 26 – Decomposição de regiões: (a) Região original em tons de cinza, (b) Primeira decomposição, (c) Segunda decomposição e (d) Terceira decomposição. . . . .	48
Figura 27 – Resultado da aplicação de geometria côncava. . . . .	49
Figura 28 – Gráfico de caixa para F-score e esquema de cores usando HOG. . . . .	52
Figura 29 – Gráfico de caixa para F-score e esquema de cores usando Função K de Ripley. . . . .	54

Figura 30 – Exemplos de caso de sucesso (a) e de falha (b) do classificador. . . . .	56
Figura 31 – Imagens em tons de cinza e equalizadas. (a) Sucesso e (b) falha. . . . .	57
Figura 32 – Geometrias definidas pelo Alpha-Shapes. (a) Sucesso e (b) falha. . . . .	57

---

# Lista de Tabelas

Tabela 1 – Comparação do desempenho das metodologias de classificação de câncer de pele a partir de imagens dermatoscópicas. . . . .	18
Tabela 2 – Quantidade de características geradas para cada configuração do descritor HOG . . . . .	45
Tabela 3 – Quantidade de características geradas para cada configuração da análise de textura. . . . .	46
Tabela 4 – Matriz de confusão para duas classes. . . . .	50
Tabela 5 – Resultados obtidos através de extração de características com HOG. . . . .	51
Tabela 6 – Resultados obtidos através de análise espacial com Função K de Ripley . . . . .	53
Tabela 7 – Resultados obtidos usando Alpha Shapes como descritor de forma. . . . .	54
Tabela 8 – Comparação com trabalhos relacionados. . . . .	55

# Lista de Abreviaturas e Siglas

ABCD	Assimetria, Borda, Cor e Diâmetro
CADe	<i>Computer-Aided Detection</i>
CADx	<i>Computer-Aided Diagnosis</i>
CNN	<i>Convolutional Neural Network</i>
FN	<i>False Negative</i>
FP	<i>False Positive</i>
HOG	<i>Histogram of Oriented Gradient</i>
HSB	<i>Hue, Saturation and Brightness</i>
HSI	<i>Hue, Saturation and Intensity</i>
HSV	<i>Hue, Saturation and Value</i>
ISDIS	<i>International Society for Digital Imaging of the Skin</i>
ISIC	<i>International Skin Imaging Collaboration</i>
kNN	<i>k Nearest Neighbors</i>
LBP	<i>Local Binary Patterns</i>
MLP	<i>Multilayer Perceptron</i>
MVS	<i>Máquinas de Vetor de Suporte</i>
PH <sup>2</sup>	<i>Pedro Hispano Hospital</i>
RBF	<i>Radial Base Function</i>
RGB	<i>Red, Green and Blue</i>
RFs	<i>Random Forests</i>
SIFT	<i>Scale-Invariant Feature Transform</i>
SV	<i>Support Vector</i>
SVM	<i>Support Vector Machines</i>

TDE	Transformada de Distância Euclidiana
TN	<i>True Negative</i>
TP	<i>True Positive</i>
TWP	Transformada de <i>Wavelet Paket</i>
UMCG	<i>University Medical Center Groningen</i>
VC	Visão Computacional

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
<b>1.1</b>	<b>Trabalhos Relacionados</b>	<b>16</b>
<b>1.2</b>	<b>Objetivos</b>	<b>18</b>
1.2.1	Objetivos Específicos	19
<b>1.3</b>	<b>Contribuições</b>	<b>19</b>
<b>1.4</b>	<b>Organização do Trabalho</b>	<b>20</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>21</b>
<b>2.1</b>	<b>Processamento de Imagens Digitais</b>	<b>23</b>
<b>2.2</b>	<b>Pré-processamento</b>	<b>25</b>
2.2.1	Equalização de Histograma	26
2.2.2	Realce Logarítmico	27
<b>2.3</b>	<b>Extração de Características</b>	<b>27</b>
2.3.1	HOG - Histograms of Oriented Gradient	28
2.3.2	Função K de Ripley	31
2.3.3	Análise Geométrica	32
2.3.4	<i>Alpha-Shapes</i>	34
<b>2.4</b>	<b>Reconhecimento de Padrões e Aprendizado de Máquina</b>	<b>36</b>
2.4.1	Máquinas de Vetor de Suporte	37
<b>3</b>	<b>METODOLOGIA</b>	<b>41</b>
<b>3.1</b>	<b>Aquisição de Imagens</b>	<b>41</b>
<b>3.2</b>	<b>Pré-Processamento e Preparação da Imagem</b>	<b>42</b>
<b>3.3</b>	<b>Extração de Características</b>	<b>43</b>
3.3.1	Descritores HOG	44
3.3.2	Função K de Ripley	45
3.3.3	Geometria Côncava	46
<b>3.4</b>	<b>Treinamento e Classificação</b>	<b>48</b>
<b>3.5</b>	<b>Validação</b>	<b>49</b>
<b>4</b>	<b>RESULTADOS</b>	<b>51</b>
<b>4.1</b>	<b>Comparação com Trabalhos Relacionados</b>	<b>54</b>
<b>4.2</b>	<b>Discussão</b>	<b>55</b>
4.2.1	Estudo de Caso	56
<b>5</b>	<b>CONCLUSÃO</b>	<b>59</b>

<b>REFERÊNCIAS</b>	<b>61</b>
--------------------	-----------

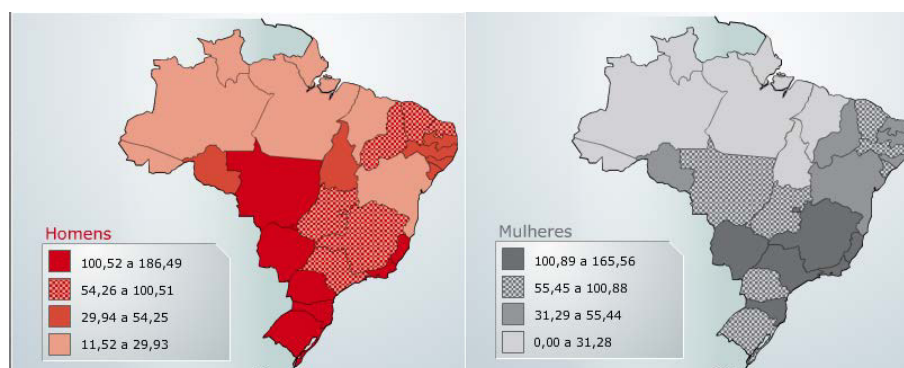
# 1 Introdução

O melanoma, apesar de ser considerado o tipo de câncer de pele mais letal, pode apresentar elevados índices de cura quando diagnosticado em seu estágio inicial. A doença pode se manifestar em pele normal com o surgimento de uma pinta com tonalidade escura e bordas irregulares, podendo vir acompanhada de coceira e descamação, ou a partir de uma lesão pigmentada pré-existente, onde o tumor irá evoluir apresentando mudanças de cores, variando de marrom ao preto, e aumento da área da lesão (SOARES, 2008).

A última estimativa mundial, em 2012, apresentou que 232 mil novos casos de melanoma seriam diagnosticados em todo o globo. Enquanto que, para a mortalidade, foram estimados 55 mil óbitos, sendo os países com população caucasiana os lugares com maiores taxas de incidência de câncer de pele. Oceania, Europa e América do Norte são os continentes em que foram verificados mais de 80% dos diagnósticos de melanomas e 65% dos óbitos por esse câncer. Atualmente, estima-se, para homens e mulheres, respectivamente, 80.850 e 94.910 novos casos de neoplasia não melanoma no Brasil, cujos valores correspondem a um risco estimado de 81,66 casos novos a cada 100 mil homens e 91,98 para cada 100 mil mulheres (INCA, 2016).

O Maranhão apresenta uma taxa estimada de 0,98 novos casos de melanoma e 22,51 novos casos de outras neoplasias malignas da pele a cada 100 mil homens. Para mulheres, as taxas são de 0,78 para novos casos de melanoma e 15,92 para outros casos de neoplasias malignas de pele. Na região nordeste, o câncer de pele não melanoma é o mais frequente entre os problemas cancerígenos no sexo feminino e, no masculino, é o segundo mais frequente (INCA, 2016). Na Figura 1, destacam-se as taxas brutas de incidência de neoplasias malignas da pele a cada 100 mil indivíduos, estimadas para o ano de 2016.

Figura 1: Representação espacial das taxas brutas de incidência de neoplasias malignas de pele a cada 100 mil homens/mulheres, estimadas para o ano de 2016, segundo Unidade de Federação.



Fonte: (INCA, 2016)



Uma das técnicas utilizadas para o diagnóstico de câncer de pele é a dermatoscopia, ilustrada na Figura 2, exame realizado com uma ferramenta que consiste em um amplificador, com uma fonte de luz não-polarizada, uma lente transparente e um líquido que fica entre o instrumento e a pele. O aparelho permite a avaliação de cores e microestruturas da epiderme, junção dermoepidérmica e derme papilar que não são visíveis a olho nu.

Figura 2: Exame dermatoscópico.



Fonte: Persone Che

Entendendo a importância do diagnóstico do câncer de pele em seu estágio precoce, métodos de processamento digital de imagens estão sendo desenvolvidos com o intuito de melhorar as técnicas de diagnóstico já existentes. Essas técnicas dependem de fatores como a experiência do profissional, a qualidade da imagem adquirida do exame de dermatoscopia e as características do próprio paciente. A ideia é fornecer um modelo de classificação para diagnóstico de câncer de pele que possa diminuir os casos de diagnósticos incorretos e aumente as chances do paciente receber um tratamento em tempo hábil.

## 1.1 Trabalhos Relacionados

Essa seção apresenta uma coletânea de trabalhos que utilizam técnicas para reconhecer e classificar imagens de lesão de pele através de diferentes abordagens propondo novas ferramentas para auxiliar profissionais da saúde na detecção do câncer de pele do tipo melanoma.

Em (SOARES, 2008) foi proposto extrair descritores de cor, forma e textura, utilizando Fourier, Transformada de *Wavelet Paket* (TWP) e Máquinas de Vetor de Suporte (MVS). O método usou imagens coloridas de câncer de pele, em especial o sistema HSI devido à pouca correlação entre os componentes matiz, saturação e intensidade. As *wavelets* permitem analisar as imagens em escalas diferentes, portanto, os descritores de textura foram calculados através de medidas estatísticas a partir da multirresolução dos coeficientes *wavelets*, que, em pequenas escalas, detectam granularidade das imagens e, em grandes escalas, representam a tendência da imagem.

Em (ROSADO, 2009), um método supervisionado de classificação de lesões subcutâneas é apresentado, baseando-se no sistema de pontuação da regra ABCD<sup>1</sup>. Foi utilizado o esquema de cores em tons de cinza, extraindo o canal azul do RGB por ser o componente que permitiu melhor discriminação da lesão. Para descrever forma e textura, foram utilizados a Transformada de Distância Euclidiana (TDE) e entropia. Para a etapa de classificação, foram comparadas as técnicas MVS e K vizinhos mais próximos.

O trabalho de Alencar (2015) propôs um modelo de classificação em que as lesões de pele da base  $PH^2$  (MENDONÇA et al., 2013) são segmentadas utilizando limiarização adaptativa de Otsu sobre canal azul do esquema RGB, baseando-se em (ROSADO, 2009). Para descrição de contornos, foram utilizadas as funcionalidades *findContours*, *convexHull* e *convexityDefects*, da biblioteca OpenCv (BRADSKI, 2000). O processo de aprendizado de máquina contou com a utilização de uma Rede Neural Artificial *Multilayer Perceptron* (MLP) para classificar as imagens em nevo benigno ou melanoma.

Segundo Alfed, Khelifi e Bouridane (2016), técnicas de extração de características apresentam melhora quando combinadas com *Histogram of Oriented Gradient* (HOG) para aplicações de reconhecimento de melanoma. Em (PRIYADARSHINI; RENGINI, 2015), MVS é utilizada para reconhecimento de características extraídas através da combinação de *Local Binary Patterns* (LBP) e HOG. LBP é uma técnica de análise de textura baseada em padrões locais que, combinada com HOG, aumenta a performance de detecção consideravelmente.

Codella et al. (2015) propõe uma abordagem para detecção de melanoma a partir de imagens dermatoscópicas através da combinação de Redes Neurais Convolucionais, *sparse coding*, e SVM. Um dos benefícios dessa abordagem é que a aprendizagem não supervisionada elimina a necessidade de identificar boas características. Os resultados obtidos com essa técnica chegam a 73,9 para acurácia, 74,3 para especificidade e 73,8 para sensibilidade.

Codella et al. (2016) ainda usa, em outro trabalho, técnicas de extração de características como redes residuais profundas (HE et al., 2015), redes neurais convolucionais (KRIZHEVSKY; SUTSKEVER; HINTON, 2012), rede U-Net (RONNEBERGER; FISCHER; BROX, 2015), *sparse coding* e LBP foram combinadas com máquinas de vetor de suporte.

Em (NASR-ESFAHANI et al., 2016), foi proposto um modelo com técnicas de pré-processamento em imagens dermatoscópicas com ruídos de *University Medical Center Groningen* (UMCG) (GIOTIS N. MOLDERS; PETKOV, 2015) para alimentar uma Rede Neural Convolucional (CNN) pré-treinada. A etapa de pré-processamento consiste em corrigir problemas de iluminação, eliminando um intervalo de gradientes causado pela

<sup>1</sup> Levam em consideração características como Assimetria, Bordas, Cor e Dimensão da lesão

mudança abrupta de saturação do esquema HSV. Em seguida uma máscara de segmentação *k-means* ( $k = 2$ ) é aplicada às imagens que, depois de algumas operações morfológicas, são inseridas na CNN.

Uma técnica que utiliza *Random Forests* (RFs) como algoritmo de reconhecimento de padrões é apresentada em (RASTGO et al., 2016), onde três representações de características são utilizadas: *Scale-Invariant Feature Transform* SIFT, matiz e histogramas de ângulos opostos e intensidade de RGB. O treinamento ocorreu através de validação cruzada com 10 divisões sobre a base de imagens PH<sup>2</sup>.

Em (BAKHEET, 2017), características HOG otimizadas são usadas em conjunto com SVM para detecção de melanoma. A região de interesse é segmentada usando limiar adaptativo e operações morfológicas. O treino e teste foi realizado usando o esquema *leave-one-out* que consiste em separar uma imagem para teste, enquanto que as outras são usadas para treinamento. Esse processo se repete para cada imagem, gerando N iterações, sendo N igual ao tamanho da base.

Tabela 1: Comparação do desempenho das metodologias de classificação de câncer de pele a partir de imagens dermatoscópicas.

Trabalho	Características	Classificador	Base (Qtd)	Acc	P	E	S
(SOARES, 2008)	Cor, Fourier e TWP	SVM	- (21)	-	100%	90%	-
(ROSADO, 2009)	Cor, TDE e entropia	kNN	PH <sup>2</sup> (48)	-	-	61%	82%
(ALENCAR, 2015)	Cor e contornos	MLP	PH <sup>2</sup> (50)	86,66%	-	-	-
(PRIYADARSHINI; RENGINI, 2015)	LBP e HOG	SVM	- (20)	-	-	93%	97%
(CODELLA et al., 2015)	<i>Deep Features</i>	SVM	ISIC (2624)	73,9%	-	74,3%	73,8%
(CODELLA et al., 2016)	<i>Deep Features</i>	SVM	ISIC (900)	81%	-	83,2%	72%
(NASR-ESFAHANI et al., 2016)	<i>Deep Features</i>	CNN	UMCG (170)	81%	75%	80%	81%
(RASTGO et al., 2016)	Cor e SIFT	RFs	PH <sup>2</sup> (193)	-	-	90,3%	100%
(ALFED; KHELIFI; BOURIDANE, 2016)	Cor, SIFT e (HOG)	SVM e kNN	PH <sup>2</sup> (176)	-	-	88,1	91,2%
(BAKHEET, 2017)	Forma (HOG)	SVM	PH <sup>2</sup> (200)	97,32%	-	96,43%	98,21%

A Tabela 1 apresenta um resumo dos trabalhos abordados na seção, trazendo também os resultados obtidos por estes em termos de acurácias, precisão, especificidade e sensibilidade quando disponíveis. A maioria dos trabalhos relatados mostram resultados bons ou promissores. Em relação às características usadas para diferenciar lesões de câncer de pele de lesões normais, tem-se, geralmente, descritores extraídos através de análises de textura, forma ou que combinam duas ou mais técnicas em uma metodologia híbrida.

## 1.2 Objetivos

O objetivo deste trabalho é propor um modelo de classificação para diagnóstico de câncer de pele através de um processo supervisionado de aprendizagem de máquina denominada Máquinas de Vetor de Suporte (SVM - *Support Vector Machines*), comparando diferentes abordagens de extração de características, sendo elas: Histogramas de Gradientes Orientados (HOG - *Histogram of Oriented Gradients*), Função K de Ripley e Geometria Côncava (*Alpha-Shapes*) extraídas das imagens dermatoscópicas de lesão de pele.

### 1.2.1 Objetivos Específicos

Para alcançar o objetivo geral deste trabalho, tem-se como metas específicas:

- Adaptar e aplicar conceitos de aprendizagem de máquina para reconhecimento de padrões;
- Adaptar e aplicar técnicas de suavização e realce de imagens digitais;
- Aplicar os Histogramas de Gradientes Orientados (HOG - *Histogram of Oriented Gradient*) para descrição de forma com intuito de auxiliar o reconhecimento de regiões suspeitas de melanoma;
- Aplicar a Função K de Ripley para descrição de textura de lesões extraídas de imagens dermatoscópicas com a finalidade de reconhecimento de câncer melanoma;
- Adaptar e aplicar Geometria Côncava para descrição de formas em imagens dermatoscópicas com a finalidade de reconhecimento de lesões malignas de pele;
- Avaliar a metodologia proposta por meio de experimentos, usando bases públicas de imagens dermatoscópicas;
- Comparar esta metodologia com as já utilizadas na literatura;

### 1.3 Contribuições

Destacam-se como principais contribuições:

- Melhoria da qualidade do diagnóstico médico baseado em imagens no âmbito médico-hospitalar;
- Contribuição para o resgate de casos de câncer, em condição mais precoce e mais apta ao tratamento curativo, preservando vidas;
- Introdução de uma opinião complementar no que tange o diagnóstico de neoplasias de pele, contribuindo para diminuir os procedimentos desnecessários no caso de erro da detecção/diagnóstico;
- A difusão da tecnologia desta pesquisa pode contribuir para uma redução significativa dos custos diretos ligados à hospitalização e a intervenções cirúrgicas desnecessárias, bem como economias de custos indiretos devidos ao afastamento do trabalho de pacientes que se beneficiariam de condutas mais precisas e precoces.

## 1.4 Organização do Trabalho

Este trabalho está estruturado da seguinte forma:

- O Capítulo 2 trata da fundamentação teórica das técnicas utilizadas neste estudo. São abordados conceitos referentes ao câncer de pele melanoma, imagens dermatoscópicas, técnicas de pré-processamento de imagens, técnicas de extração de características com Histograma de Gradientes Orientados, Função K de Ripley e Geometria Côncava, reconhecimento de padrões e Máquinas de Vetor de Suporte;
- O Capítulo 3 apresenta as etapas adotadas que compõem a metodologia proposta para este trabalho. São mostradas as configurações dos parâmetros utilizados para o pré-processamento e a extração das características, bem como os passos tomados para a realização do treinamento e reconhecimento de padrões;
- O Capítulo 4 trata sobre os resultados obtidos em relação aos experimentos realizados na base de imagens públicas de dermatoscopia ISIC; e
- O Capítulo 5 apresenta as considerações finais sobre os resultados e trabalhos futuros.

## 2 Fundamentação Teórica

O câncer melanoma é o tipo de neoplasia de pele menos frequente, porém é o mais perigoso, devido à alta probabilidade de metástase<sup>1</sup> e que possui consequências mais devastadoras. Se diagnosticado em seu estágio inicial e devidamente tratado, estima-se um índice de cura acima de 90%. Pode ser caracterizado por uma pinta com uma taxa de crescimento progressivo e que tenha apresentado mudança repentina de alguma de suas características, como cor, borda ou textura.

O melanoma pode surgir a partir de pele normal ou de uma lesão pigmentada pré-existente (SOARES, 2008). Em pele normal, a manifestação pode ocorrer com o aparecimento de uma mancha com bordas irregulares que talvez apresente sintomas como coceira e descamação. A grande maioria das lesões não apresenta sintoma algum (JR; ODOM; JAMES, 1995). Em caso de lesão pré-existente, acontece um aumento do tamanho, mudança na pigmentação e na forma da lesão, além de passar a apresentar bordas irregulares.

O câncer de pele melanoma tem origem em células especiais cuja função é produzir melanina<sup>2</sup>, os melanócitos, e predomina em pessoas brancas e adultas. Apesar de ser considerado raro em crianças, é necessário fazer o acompanhamento de sinais de tamanho demasiado, chamadas de nevo gigante, já que o melanoma pode surgir a partir dessas regiões.

As pessoas que têm maiores chances de apresentar a doença são aquelas com pele clara (pouca melanina) que sofreram queimaduras solares quando criança ou pessoas com histórico de melanoma na família (SOARES, 2008). Os fatores de riscos que propiciam este tipo de câncer são: sensibilidade ou intolerância total ao sol, pele clara, exposição excessiva ao sol, histórico familiar de qualquer tipo de câncer de pele, reincidência, nevo congênito (pinta escura), nevo displásico (lesão escura da pele com células pré-cancerosas) e idade (há probabilidade maior de apresentar a doença em pessoas com mais de 15 anos).

As maiores chances de cura do melanoma são quando diagnosticado precocemente, ou seja, quando as células cancerosas ainda estão apenas na superfície da pele. A cirurgia (remoção total da lesão) é o tratamento mais indicado, porém a radioterapia, quimioterapia e imunoterapia também podem ser solicitadas a depender do estágio do câncer. Se não for retirado em seu estágio inicial, pode ocorrer a metástase, que acaba invadindo as camadas saudáveis da pele, disseminando para outras regiões do corpo, o que torna o controle da doença mais difícil.

---

<sup>1</sup> Migração por via sanguínea ou linfática de produtos patológicos (vírus, bactérias, parasitas e especialmente células cancerosas) provenientes de uma lesão inicial.

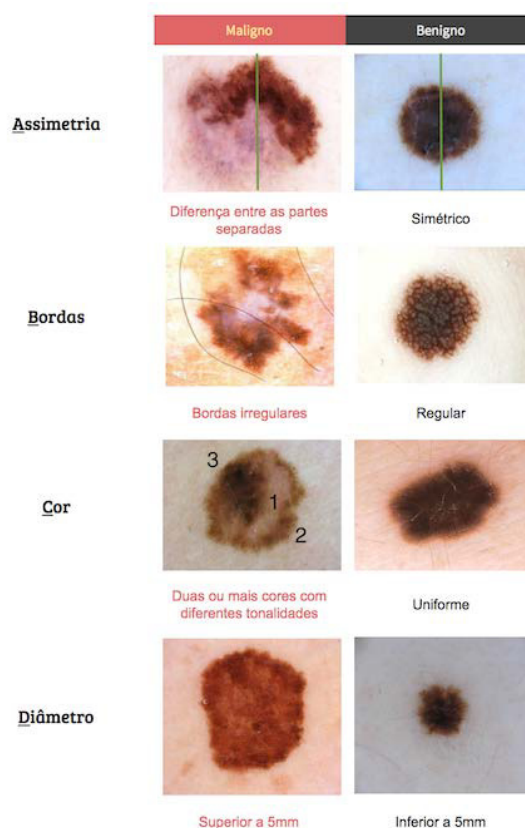
<sup>2</sup> Substância que determina a cor da pele.

Para diagnosticar o câncer, o paciente deve ser submetido a uma biópsia, que é a única forma de diagnóstico definitivo. Nesse procedimento, toda a lesão, ou pelo menos parte dela, é retirada para ser analisada por um especialista por meio de um microscópio. A análise busca presença de células cancerosas e, geralmente, deve ser feita por dois ou mais patologistas (JR; ODOM; JAMES, 1995).

Além da biópsia, existem alguns exames que servem para detecção e prevenção do câncer de pele. Um deles é a dermatoscopia, técnica não-invasiva, no qual o dermatologista usa um aparelho chamado dermatoscópio para fotografar a região da lesão, aumentando-a de 10 a 70 vezes, que facilita a análise e documentação das manchas e pintas. Portanto, esse exame possibilita averiguar regiões que têm chances de ser um tumor maligno, atuando na prevenção do câncer de pele. A precisão do diagnóstico chega a 97% (SOARES, 2008), evitando cirurgias desnecessárias.

Ainda, tendo em vista o reconhecimento de sinais e sintomas do câncer de pele, é necessária a avaliação do próprio corpo, levando em consideração a regra chamada ABCD (SOARES, 2008) (Figura 3).

Figura 3: Dermatoscopias mostrando a Regra ABCD.



Fonte: Elaborada pelo autor

As iniciais significam: **A**ssimetria - onde, ao realizar um corte mediano na lesão, um lado não é igual ao outro; **B**ordas - as quais geralmente são irregulares no seu contorno,

apresentando certas imperfeições; **Cor** - essa característica não apresenta uniformidade, ou seja, frequentemente, possui duas ou mais tonalidades, podendo ser escuras, marrons, avermelhadas ou até azuladas; e, por último, **Diâmetro** - lesões malignas modificam seu tamanho, aumentando a área da lesão que, na maioria dos casos, passam de 5mm (JR; ODOM; JAMES, 1995).


Os aspectos do melanoma variam muito de indivíduo para indivíduo. Muitos apresentam características de toda a regra ABCD, porém outros podem sofrer modificações em apenas um ou dois dos itens supracitados.

## 2.1 Processamento de Imagens Digitais

O processamento de imagens pode ser considerado como uma ou mais alterações realizadas sobre os elementos que as compõem, os pixels, com intuito de melhorar aspectos visuais de certas estruturas que possibilitem uma determinada interpretação da imagem. Os métodos de processamento de imagens, historicamente, vieram com a necessidade de melhorar a qualidade de informação para a compreensão humana (BRAZ JUNIOR et al., 2014).

Existem inúmeros algoritmos para processamento de imagens, cada um com finalidades bastante específicas. O conjunto de diferentes algoritmos escolhidos formam uma metodologia, que geralmente acompanha as etapas apresentadas por (GONZALEZ; WOODS, 2006), como pode ser visto na Figura 4.

Figura 4: Passos fundamentais em processamento de imagens digitais.



Fonte: Adaptado de Gonzalez e Woods (2006)

As etapas envolvidas no processo giram em torno de uma base de conhecimento intrinsecamente ligada ao domínio do problema e, dentre elas, estão: aquisição de imagens, representando o problema a ser investigado; pré-processamento, buscando melhoria e realce das características presentes nas imagens; segmentação, onde a região de interesse é separada das estruturas irrelevantes ao problema; representação e descrição, ligado à




organização das informações; e, finalmente, a etapa de reconhecimento, na qual os padrões encontrados nas informações são interpretados.

Uma imagem é, geralmente, uma projeção 2D de uma cena 3D capturada por algum sensor (DAWSON-HOWE, 2014). É a representação de um objeto que emite ou recebe luz e que é formada por raios luminosos que passam por uma lente, espelho ou qualquer outro sistema óptico. Consiste em uma função de intensidade de luz de duas dimensões apresentada por  $f(i, j)$ , onde  $i$  e  $j$  são as coordenadas espaciais e o valor da função  $f$  é proporcional à luminosidade da imagem no ponto  $(i, j)$ .

Para representar uma imagem de forma digital, é preciso fazer amostras de  $f(i, j)$  na forma de um matriz de dimensão  $N \times M$ , em que cada elemento é uma quantidade discreta da intensidade luminosa, que é dividida em  $k$  intervalos, com valor geralmente igual a 256. Ou seja, para uma imagem monocromática<sup>3</sup>, pode-se ter até 256 tons diferentes de uma única cor para compô-la. Na Figura 5, destaca-se a representação em pixels de uma imagem em tons de cinza.

Figura 5: Representação de uma imagem digital.



Fonte: Elaborada pelo autor

As imagens coloridas podem ser obtidas a partir da combinação de três cores básicas: vermelho, verde e azul, em inglês *Red*, *Green* e *Blue*, cujas iniciais formam o nome do esquema. Então, cada pixel da imagem terá três valores associados a cada canal, que, quando unidas, formam a cor final. Pode-se imaginar, portanto, que uma imagem RGB é composta de três matrizes  $N \times M$ , representando os canais R, G e B, mostrada na Figura 6.

Existem outros sistemas para representar cores, como por exemplo o HSV. Sigla que vem de *Hue* (matiz), *Saturation* (saturação) e *Value* (valor), podendo ainda ser chamada de HSB, onde B significa *Brightness* (brilho). A matiz representa a cor propriamente dita, vindo do espectro visível que vai do vermelho ao violeta, com valores de 0 a 360 mais o

<sup>3</sup> Quando diferentes tons de uma única cor são usados para montar uma imagem.


Figura 6: Superposição de matrizes para imagens coloridas (RGB).

0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	18	82	0	0	83	94	59	0	0	0	0
0	0	10	198	72	37	72	27	61	9	0	0	0
0	0	11	18	61	63	54	35	22	0	0	0	0
0	0	123	43	63	87	5	12	123	0	0	0	0
0	0	111	121	23	24	215	112	11	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0

Fonte: Elaborada pelo autor

magenta<sup>4</sup>. A saturação denota o quão "puro" uma cor é, ou seja, quanto menor o seu valor (0 a 100%), mais próximo de cinza a cor está e, caso contrário, mais pura a cor vai ser. Já o último canal representa o brilho na cor, que atinge valores de 0 a 100%. Esse sistema de cores pode ser resumido em um cone, representado na Figura 7.

Figura 7: Representação do esquema de cores HSV.



Fonte: Repositório Wikimedia Commons

Cada problema pode ser analisado e resolvido utilizando infinitas combinações de algoritmos a fim de alcançar os resultados desejados. A seguir, serão abordados conceitos e definições fundamentais das técnicas exploradas na metodologia deste trabalho e estão divididas de acordo com as etapas fundamentais do processamento de imagens.

## 2.2 Pré-processamento

Esta etapa é considerada de vital importância para as fases que a procedem; pois, é nesta etapa, que as regiões de interesse para o problema tratado são realçadas, enquanto

<sup>4</sup> Resultado da mistura de das ondas do espectro de luz azul e vermelha, não estando, portanto, em uma faixa separada

que ruídos indesejados devem ser removidos. Para o desenvolvimento da metodologia proposta por este trabalho, foram utilizadas as técnicas de equalização de histogramas e realce logarítmico.

### 2.2.1 Equalização de Histograma


O histograma é uma representação gráfica da distribuição de intensidade na imagem. Quantifica o número de pixels para cada valor de intensidade existente no canal, como é mostrado na Figura 8, onde no item (a) tem-se a imagem normal em RGB, no item (b) separou-se o canal vermelho para extração do histograma representado no item (c).

O método de equalização de histograma melhora o contraste de uma imagem, atenuando sua intensidade por meio do alargamento da amplitude horizontal dado pelo histograma. Consiste em uma transformação não-linear que considera a distribuição cumulativa da imagem original, para gerar uma imagem resultante, cujo histograma será aproximadamente uniforme. A função de transformação pode ser calculada por:

$$g(i, j) = h(f(i, j)) \times c \quad (2.1)$$

onde  $g$  é o novo valor do pixel no ponto  $(i, j)$ ,  $h$  é a função de distribuição cumulativa aplicada à imagem original  $f(i, j)$  e  $C$  é uma constante.

Figura 8: (a) Imagem de melanoma. (b) Canal vermelho da imagem e (c) Histograma correspondente.

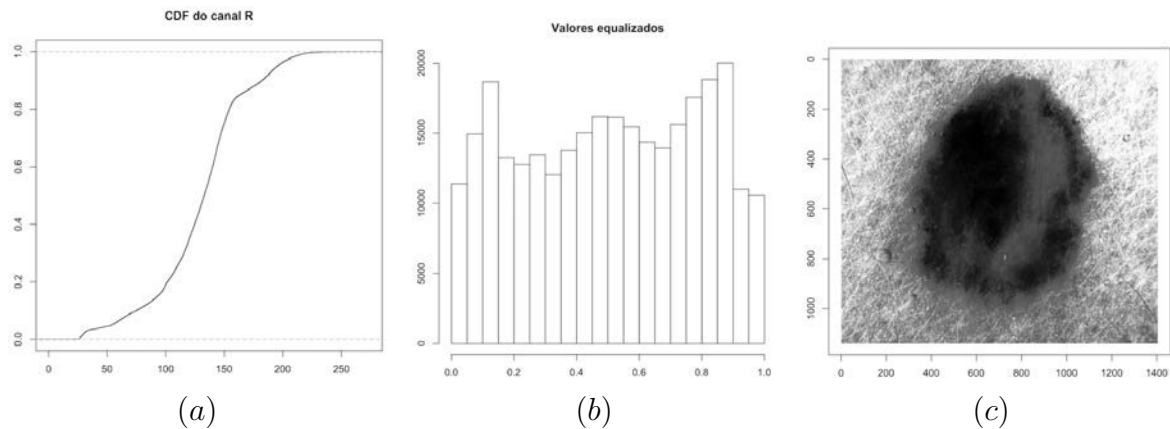


Fonte: Elaborada pelo autor

Na Figura 8 (c), pode-se notar que as intensidades se encontram aglomeradas no centro do histograma, causando um alto pico de intensidade. A equalização ameniza esse pico, distribuindo os valores de pixels para intensidades vizinhas que leva a um ligeiro alargamento da base, como pode ser verificado na Figura 9. O item (a) mostra a função

de distribuição cumulativa (CDF - *Cumulative Distribution Function*) para os valores do canal vermelho. O item (b) apresenta o histograma equalizado, onde é possível notar a redistribuição uniforme dos pixels ao longo da base. E, no item (c), tem-se o resultado da equalização do histograma no canal estudado.

Figura 9: (a) DFA. (b) Histograma equalizado e (c) Imagem resultante do canal.



Fonte: Elaborada pelo autor

### 2.2.2 Realce Logarítmico

Levando em consideração o histograma de uma imagem, o realce logarítmico mapeia uma faixa de valores baixos de intensidade luminosa de entrada para faixas maiores na saída. Quanto às faixas de altos valores, o oposto acontece (BRAZ JUNIOR et al., 2014). Esta operação serve para tornar mais visível regiões da imagem que se encontram escuras.

Sendo  $g(i, j)$  o novo valor do pixel na imagem, a transformação é realizada através da seguinte equação:


$$g(i, j) = c \times \log(1 + f(i, j)) \quad (2.2)$$

onde  $c$  é uma constante escolhida arbitrariamente e  $f(i, j)$  é o valor original do pixel na posição  $(i, j)$ . Na Figura 10, mostra-se um exemplo de aplicação desse tipo de realce.

## 2.3 Extração de Características

Esta etapa busca extrair informações relevantes que melhor rotulam um determinado padrão, ou seja, são aqueles atributos cujos valores servem como assinatura para uma certa categoria dentro do espaço do problema tratado. Esta fase precede a de reconhecimento de padrões, pois seus resultados servem como valores de entrada para a etapa seguinte.

Figura 10: (a) Canal vermelho e (b) realce logarítmico.



Fonte: Elaborada pelo autor

Este trabalho usa as técnicas de cálculo de Histograma de Gradientes Orientados e Função K de Ripley para descritores de características e são descritos a seguir.

### 2.3.1 HOG - Histograms of Oriented Gradient

HOG significa Histogramas de Gradientes Orientados, do inglês *Histograms of Oriented Gradient*. O gradiente é uma medida de mudança de valor ao redor de um pixel em relação ao seu eixo  $x$  e  $y$ . Ou seja, para cada pixel, subtrai-se os valores de intensidade dos que estão à esquerda e à direita, e dos que estão acima e abaixo. O resultado é um vetor denominado vetor gradiente. A ordem escolhida para subtrair os pixels não é importante, desde que seja consistente ao longo de toda a imagem. O vetor gradiente é calculado por:

$$\begin{cases} \Delta f(i, j)_x = f(i - 1, j) - f(i + 1, j) \\ \Delta f(i, j)_y = f(i, j - 1) - f(i, j + 1) \end{cases} \quad (2.3)$$

onde  $\Delta f(i, j)$  representa a variação de valor para a posição  $(i, j)$ . Com o vetor gradiente calculado, pode-se extrair os valores de magnitude e ângulo com as equações a seguir.

Magnitude:


$$\sqrt{\Delta f(i, j)_x^2 + \Delta f(i, j)_y^2} \quad (2.4)$$

Ângulo:

$$\arctan \frac{\Delta f(i, j)_x}{\Delta f(i, j)_y} \quad (2.5)$$

Por exemplo, considere a Figura 11, onde se é mostrada a vizinhança de um determinado pixel. Para calcular seu vetor gradiente, usa-se o esquema mostrado na

Figura 11: Ilustração dos vizinhos de um determinado pixel.



Fonte: Elaborada pelo autor

fórmula 2.3:

$$\begin{cases} \Delta f(i, j)_x = 48 - 51 = -3 \\ \Delta f(i, j)_y = 47 - 52 = -5 \end{cases} \quad (2.6)$$

O vetor  $(-3, -5)$  representa o gradiente do pixel apresentado na imagem. Os valores de magnitude e ângulo calculados respectivamente por 2.4 e 2.5 são 5.83 e  $30.96^\circ$ .


A ideia básica por trás dos histogramas de gradientes orientados é que a aparência e forma de um objeto pode ser caracterizada pela distribuição de intensidades de gradientes locais ou bordas (DALAL; TRIGGS, 2005). A intenção do descritor HOG é generalizar um objeto de tal forma que o mesmo objeto produz os mesmos valores de características em diferentes condições, isto é, invariantes a ângulos e escalas.

Para computar o descritor HOG, a imagem é dividida em pequenos quadrados, denominados células, delimitados por uma janela de detecção. Estas células são agrupadas em blocos deslizantes (Figura 12). Os tamanhos da janela, dos blocos e das células vão depender do problema a ser tratado e de quantas características se deseja extrair.

É, então, calculado o vetor gradiente em cada pixel disposto em uma célula. Todos os gradientes calculados são agrupados em posições de um vetor de tamanho  $n$ , chamados de *bins*. Tem-se então um histograma de gradientes de tamanho  $n$  para uma determinada célula. Cada gradiente tem ainda uma magnitude associada, que causa impacto proporcional ao seu valor no histograma, onde a contribuição é dividida entre as duas posições mais próximas no vetor.


Por exemplo, se existem 9 posições no histograma, variando de  $20^\circ$  em  $20^\circ$ , como em (DALAL; TRIGGS, 2005), e, se um gradiente possui ângulo  $85^\circ$ , é adicionado  $\frac{1}{4}$  da magnitude para o *bin* centrado em  $70^\circ$  e  $\frac{3}{4}$  para o centrado em  $90^\circ$ , como ilustra a Figura

Figura 12: Configuração de extração de HOGs em uma imagem.



Fonte: (DALAL; TRIGGS, 2005)

Figura 13: Distribuição de magnitudes de gradientes.



Fonte: Adaptado de Dalal e Triggs (2005)

13. A ideia de dividir a contribuição de cada gradiente serve para diminuir o problema de gradientes que residem bem nas bordas dos *bins* do histograma.

Após o cálculo do histograma de cada célula, o bloco é, então, levado em consideração. Cada bloco vai possuir um vetor de tamanho dado pelo número de *bins* multiplicado pelo número de células que compõem o bloco. Em (DALAL; TRIGGS, 2005), foram utilizados blocos com 4 células e 9 *bins*, resultando em um vetor de tamanho 36. Esse vetor é dividido pela sua norma para normalizá-lo.

O bloco deslizante de forma sobreposta faz com que os histogramas das células sejam normalizados por diferentes vizinhos. O número de características final  $F$  é calculado

por:

$$F = B_x \times B_y \times c \times b \quad (2.7)$$

onde  $F$  é número de características calculado,  $B_x$  é o número de blocos deslizados no sentido horizontal,  $B_y$  é o número de blocos deslizados no sentido vertical,  $c$  é o número de células por bloco e  $b$  é número de *bins* considerado para o histograma de gradientes.

### 2.3.2 Função K de Ripley

A maioria das estruturas no mundo natural não são homogêneas, mas exibem algum tipo de padrão espacial, seja ela em uma visão macro, como corpos celestes, ou micro, como um conjunto de células biológicas, sendo, portanto, possível ser resumido em um determinado padrão de pontos. Uma série de ferramentas vem sendo utilizadas, que se baseiam em distribuições como a de Poisson<sup>5</sup> para criar modelos de inferências sobre padrões (MARTINS et al., 2007).

Padrões em pontos vêm sendo estudados por longo período na área da estatística e usam, geralmente, distâncias como medidas para objetos de estudo mapeados em um plano ou espaço. Os estudos podem ser feitos em análises de primeira ou segunda ordem. Na primeira ordem, preocupa-se com o modo no qual um valor esperado varia ao longo do espaço, já na abordagem de segunda ordem, descreve-se a correlação entre valores em diferentes regiões do espaço (HAASE, 1995).

A Função K de Ripley (RIPLEY, 1977) é um método de análise de segunda ordem comumente utilizada em análise de dados espaciais. Essa função pode ser usada para resumir certos padrões de pontos, testar hipótese, estimar parâmetros e ajustar modelos (BRAZ JUNIOR et al., 2014). É definida por:


$$R(d, i) = \sqrt{\frac{Ak(i, j)}{N}}, \quad i \neq j \quad (2.8)$$

onde  $d$  é a distância entre o ponto a ser analisado e o ponto de referência,  $i$ , que é o centro do parâmetro área  $A$ ,  $k$  é um função que verifica se o ponto  $j$  está dentro de  $A$  em relação a  $i$  e  $N$  é o número de pontos analisados. Na Figura 14, é apresentada uma análise de indivíduos de duas classes (azul e vermelha) através de uma área circular de raio  $r$  centrada em  $i$ .

De uma forma geral, a função K de Ripley calcula uma relação do número de indivíduos de uma determinada espécie distribuída em uma região adotada, que pode ser circular, em anéis, quadrática ou até formas complexas.

<sup>5</sup> Em teoria de probabilidade e estatística, é uma distribuição que expressa a probabilidade de um dado número de eventos ocorrer em um intervalo fixo de tempo/espaço se esses eventos ocorrem com uma taxa média conhecida e independentemente do tempo do último evento.



Figura 14: Análise de Ripley com área circular de raio  $r$ .

Fonte: Elaborada pelo autor

### 2.3.3 Análise Geométrica

É o estudo das formas de objetos usando medidas que caracterizam sua forma ou aparência. Em relação à forma, pode-se analisar se uma região é circular ou retangular por exemplo. Já para aparência, busca-se investigar o comportamento do contorno ou métricas calculadas através da área do objeto estudado.

Considerando que lesões de pele surgem de pintas congênitas ou adquiridas com o tempo e partindo do pressuposto que essas lesões apresentam características de círculos, as medidas utilizadas neste estudo calculam aspectos de distribuição de pontos em forma circular, sendo elas: Excentricidade, Circularidade, Compacidade, Solidicidade, Orientação (MONTERO; BRIBIESCA, 2009), Desproporção Circular, Densidade Circular (SOUSA et al., 2010), Densidade Quadrangular, Densidade Anular e Densidade Quadrática proposta em (BRAZ JUNIOR et al., 2014). O que significa cada medida e como são calculadas são descritas a seguir.

- Excentricidade calcula o quão desproporcional é um eixo em relação ao outro.

$$E = \frac{\min Axis}{\max Axis} \quad (2.9)$$

onde  $\min Axis$  representa o eixo menor e  $\max Axis$ , o maior.

- Circularidade informa o quão circular é um determinado objeto em relação ao seu perímetro  $P$  baseado em sua área  $A$ .

$$C = \frac{4\pi A}{P^2} \quad (2.10)$$

- Compacidade mede o quão compacto um objeto é em relação ao seu perímetro.

$$C_o = \frac{P^2}{4\pi A} \quad (2.11)$$

onde  $A$  é a área e  $P$  é o perímetro do objeto.

- Solidicidade calcula a distribuição da área  $A$  do objeto em relação a sua área convexa  $A_{convexa}$ , verificando se existem falhas nas bordas.

$$S = \frac{A}{A_{convexa}} \quad (2.12)$$

- Desproporção Circular calcula o quanto uma região é proporcional a um círculo que a envolve.

$$D = \frac{P}{2\pi Re} \quad (2.13)$$

onde  $P$  é o perímetro e  $Re$  é o raio do círculo envolvente.

- Densidade Circular proporção da área do objeto (dado em pontos) em relação à área de um círculo que o envolve.

$$D_c = \frac{100n}{A} \quad (2.14)$$

onde  $n$  é número de pontos do objeto estudado e  $A$  é a área do círculo envolvente.

- Densidade Quadrangular análise quadrangular de como a área do objeto está distribuída.

$$Dqi = \frac{A_{i_{quadrante}}}{A_{quadrante}} \quad (2.15)$$

onde a região em estudo é dividida em quadrantes e cada quadrante ( $A_{i_{quadrante}}$ ) é comparado com a área total ( $A_{quadrante}$ ).

- Densidade Anular análise em anel de como a área do objeto está distribuída.

$$Da = \frac{A_{i_{anel}}}{A_{anel}} \quad (2.16)$$

onde a região em estudo é dividida em anéis e cada anel ( $A_{i_{anel}}$ ) é comparado com a área total ( $A_{anel}$ ).

- Densidade Quadrática calcula a proporção da área  $A$  de um objeto com a área  $A_{bb}$  de um retângulo que o envolve.

$$Dd = \frac{A}{A_{bb}} \quad (2.17)$$


Pode-se observar que as medidas escolhidas levam em consideração ou o perímetro do objeto ou a sua área. Enquanto que a área pode ser dada pela contagem de pixels da região de interesse na imagem, o perímetro pode ser definido pelo seu fecho convexo. Entretanto, as formas dos objetos em estudo podem apresentar estruturas côncavas em suas bordas ou internamente que não devem ser desconsideradas. Neste trabalho, optou-se portanto em utilizar técnicas de geometria côncava (*Alpha-Shapes*) para descrever as formas das quais as características aqui definidas serão extraídas.

### 2.3.4 Alpha-Shapes

Assumindo uma nuvem de pontos em qualquer dimensão, um conceito simples de  $\alpha$ -Shapes é dada pelo formato descrito através dos pontos, com  $\alpha$  determinando o quão fiel esse formato é, variando do mais genérico possível (fecho convexo) até o mais específico formato (o próprio conjunto de pontos). Ou seja, considerando que a nuvem de pontos seja dada pelo conjunto  $S \subset R^d$ , o formato construído por S é o próprio fecho convexo, quando  $\alpha$  é  $\infty$ , e é o próprio S, quando  $\alpha$  é 0. Portanto, à medida que o valor de  $\alpha$  decresce, o  $\alpha$ -shapes diminui proporcionalmente formando estruturas côncavas (EDELBRUNNER; MÜCKE, 1994).

O parâmetro  $\alpha$ , então, especifica a precisão do contorno do objeto. Na Figura 15, pode-se observar um exemplo da forma gerada através do  $\alpha$ -shapes. O objetivo da técnica é definir um contorno em relação ao conjunto de pontos, de modo que esse contorno corresponda à forma estabelecida pela distribuição dos pontos.

Figura 15: Alpha Shapes de um conjunto de pontos em um plano.




Fonte: (FISCHER, 2000)

Em definição formal, têm-se um  $\lambda$ -circunferência de raio  $\lambda \in [0, \infty]$ , com 0-circunferência sendo um ponto e  $\infty$ -circunferência um espaço aberto. Considerando  $b$  como uma determinada circunferência, ela é dita vazia se  $b \cap S = \emptyset$ . Então, um  $k$ -simplexo  $\Delta_T$  é considerado  $\alpha$ -exposto (Figura 16) se  $\exists \lambda$ -circunferência vazia, onde  $\Delta_T = \delta b \cap S$  e  $\delta S$  é o fecho convexo de  $k$  pontos.

Após a introdução dos conceitos de  $k$ -simplexo e  $\alpha$ -exposto, pode-se definir uma

Figura 16: À esquerda,  $k$ -simplexo  $\alpha$ -exposto. À direita,  $k$ -simplexo não  $\alpha$ -exposto



Fonte: (FISCHER, 2000)

superfície  $\delta S_\alpha$  de um conjunto de pontos  $S$  como todos os  $k$ -simplexos  $\alpha$ -expostos de  $S$ :

$$\delta S_\alpha = \Delta_T \mid T \subset S, \quad |T| \leq d \quad (2.18)$$

onde  $\Delta_T$  é  $\alpha$ -exposto e  $d$  representa a dimensão do conjunto  $S$ . O contorno  $\delta S_\alpha$  do  $\alpha$ -shapes é, para qualquer valor de  $\alpha \in [0, \infty]$ , um subconjunto da Triangulação de Delaunay (TD). Para o conjunto  $S \subset \mathbb{R}^d$ , a triangulação de Delaunay de  $S$  é o complexo simplexo  $TD(S)$  consistindo de:


- Todos os  $d$ -simplexos  $\Delta_T$  em que  $T \subset S$  de modo que a circunferência de  $T$  não contém quaisquer outros pontos do conjunto  $S$ ; e
- Todos os  $k$ -simplexos que são faces de outros simplexos válidos em  $TD(S)$ .

Se  $\Delta_T$  é  $\alpha$ -exposto, então  $\Delta_T \in TD(S)$ . Edelsbrunner e Mücke (1994) propõe calcular os  $\alpha$ -shapes a partir de uma estrutura denominada de complexo- $\alpha$  ( $C_\alpha(S)$ ), ao invés de calcular diretamente o contorno  $\delta S_\alpha$ . Para isso, é necessário verificar cada triângulo de  $TD(S)$  da seguinte forma:

- Se a circunferência que envolve o triângulo tem raio menor que  $\alpha$  e sua superfície não intersecta quaisquer outros pontos; ou
- Se  $\Delta_T$  é face para outro simplexo de  $C_\alpha(S)$ .

Desta forma, os simplexos que satisfazem uma das duas condições fazem parte do contorno e, por conseguinte, do  $\alpha$ -shape. Na Figura 17, é ilustrado um contorno formado por  $\alpha$ -shapes, a triangulação de Delaunay  $DT(S)$  e o complexo- $\alpha$  obtido.

Figura 17: Representação de um *complexo- $\alpha$*  a partir dos triângulos de  $TD(S)$ .



Fonte: (FISCHER, 2000)

## 2.4 Reconhecimento de Padrões e Aprendizado de Máquina

Reconhecimento de padrões iniciou na Engenharia, enquanto que aprendizado de máquina cresceu na área da Ciência da Computação (BISHOP, 2006). Apesar de serem dois assuntos distintos, podem ser vistos como duas faces da mesma moeda e têm tido crescimento substancial em vários campos nos últimos dez anos. São técnicas com intuito de encontrar padrões para descrever um determinado objeto a partir de características selecionadas na etapa de extração de descritores (BRAZ JUNIOR et al., 2014).

Os algoritmos de aprendizagem de máquina investigam um conjunto de dados atrás de parâmetros que definem classes distintas dispostas de forma visível ou não dentro desse espaço de busca. Esse processo é geralmente dividido em duas fases: uma, chamada de treinamento, na qual um subconjunto dos dados disponíveis são introduzidos a um algoritmo de aprendizado de máquina qualquer que vai tentar separar grupos existentes denominados classes, e outra fase chamada de classificação, onde um novo subconjunto é apresentado ao modelo para que seja determinada a classe de cada indivíduo testado.

O treinamento pode ser feito de diferentes maneiras. Entre elas estão as formas supervisionadas e não-supervisionadas. Em um treinamento supervisionado, o algoritmo de aprendizagem é apresentado a um par  $(X, Y)$ , onde  $X$  é conjunto de características e  $Y$  é o valor de sua respectiva classe. Com os valores dos rótulos previamente conhecidos e das características para cada grupo, a máquina de reconhecimento tenta achar uma associação ou padrão entre uma determinada classe e o conjunto de informações dos indivíduos que pertencem aquele grupo.

Na abordagem não-supervisionada, as classes existentes no conjunto de dados não são conhecidas, sendo, portanto, necessário que o algoritmo de reconhecimento seja capaz de encontrar similaridades entre diferentes indivíduos para que, então, eles possam ser agrupados e as classes definidas por características gerais presentes em cada subgrupo.

Essa forma de treinamento é também conhecida simplesmente por agrupamento ou por processo auto-organizável.

Com o modelo devidamente treinado, um novo exemplo, totalmente desconhecido e que não participou da fase de treinamento, é apresentado ao algoritmo que, a partir do conhecimento prévio obtido pela generalização das características usadas, rotula aquele exemplo para uma das classes conhecidas pelo método.


Na metodologia proposta por este trabalho, as Máquinas de Vetor de Suporte foram utilizadas para realizar o reconhecimento dos padrões de câncer de pele melanoma a partir da extração de características HOG e análise espacial com a Função K de Ripley.

### 2.4.1 Máquinas de Vetor de Suporte

As Máquinas de Vetor de Suporte, do inglês *Support Vector Machines* (SVM) (NAUMOVICH; VAPNIK, 1998), compõem uma técnica com fundamentação na teoria do aprendizado estatístico, introduzida por Vapnik e colaboradores, que despertou grande interesse da comunidade de aprendizado de máquina (SOARES, 2008) e tem como objetivo maximizar a capacidade de generalização.

Esse classificador tem o trabalho de segmentar duas classes através de um hiperplano que maximiza uma margem de separação denotada por  $\delta$ . Esse hiperplano está localizado entre as semi-retas  $H_1$  e  $H_2$ , que separam as classes +1 e -1 respectivamente, atingindo seu ótimo quando a distância para as duas linhas for máxima. Dois pontos da classe +1 definem a reta  $H_1$  e três, da classe -1, definem a reta  $H_2$ . Esses pontos são chamados de vetores de suporte (SV - *Support Vector*) (Figura 18).

Figura 18: Hiperplano de separação para padrões lineares.



Fonte: (SOARES, 2008)

Ilustra-se, na Figura 18, um exemplo de dados linearmente separáveis. Em caso de padrões não-lineares, as variáveis de entrada são transformadas para um domínio com maior dimensionalidade, cujo objetivo é, então, conseguir separar as classes nesse novo espaço. Porém, encontrar essa função de transformação não é trivial. Essa tarefa acontece com o auxílio de funções não-lineares denominadas *Kernels*, que torna possível a construção

de um hiperplano de separação ótimo para o espaço de características sem considerar explicitamente o espaço.

Considerando um conjunto de treinamento  $(x_i, y_i)$ , onde  $x_i \in R^N$  é o vetor de entrada,  $y_i \in \{\pm 1\}$  os rótulos de cada exemplo e  $N$  o tamanho da amostra, procura-se estimar a função dada por  $f : R^N \rightarrow \{\pm 1\}$  capaz de separar de forma correta as classes dos exemplos informados.

No treinamento a função  $f(x) = y_i(w \cdot x_i + b)$  é estimada de forma que  $w$  e  $b$  satisfaçam a seguinte inequação:

$$y_i(wx_i + b) \geq 1 \quad (2.19)$$

onde  $w$  é um vetor normal ao hiperplano de separação e  $b$  a distância ou corte da função  $f$  em relação à origem. Tem-se agora um problema de otimização dos valores  $w$  e  $b$  por meio da minimização da Equação 2.20, sujeita à restrição dada pela Equação 2.19 (BISHOP, 2006).

$$\phi(w) = \frac{w^2}{2} \quad (2.20)$$

Como o objetivo é produzir um classificador que apresenta um bom desempenho em relação a amostras excluídas durante o processo de treinamento, ou seja, um classificador com bom grau de generalização, é importante que o SVM seja capaz de minimizar erros de classificação, quando a separação perfeita das classes não for viável. Isso é resolvido, inserindo variáveis de folga de modo que a relação dada pela Equação 2.19 seja alcançada.

Portanto, o novo sistema a ser otimizado é:

$$\phi(w, \xi) = \frac{w^2}{2} + C \sum_{i=1}^N \xi_i \quad (2.21)$$

sujeito a:

$$y_i((w \cdot x_i + b) + \xi_i) \geq 1 \quad (2.22)$$

onde  $C$  é um parâmetro de treinamento que estabelece um equilíbrio entre a complexidade do modelo e o erro de treinamento, sendo um valor fornecido pelo próprio usuário.

A função objetivo a ser minimizada é convexa e possui apenas um único mínimo global (LORENA; CARVALHO, 2007), onde pode ser aplicado uma função Lagrangiana, que associa parâmetros denominados de Lagrange  $\alpha_i$  (Equação 2.23), englobando as restrições à própria função objetivo.

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i (y_i(w \cdot x_i + b) - 1) \quad (2.23)$$

Ao minimizar a função Lagrangiana, implicando em maximizar  $\alpha_i$  ao mesmo tempo que minimiza  $w$  e  $b$ , observa-se ao seguinte ponto de sela, onde:

$$\frac{\partial L}{\partial w} = 0 \quad \text{e} \quad \frac{\partial L}{\partial b} = 0 \quad (2.24)$$

Resolvendo as equações, chega-se às seguintes expressões:

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (2.25)$$

$$w = \sum_{i=1}^n \alpha_i y_i x_i \quad (2.26)$$

Substituindo as Equações 2.25 e 2.26 em 2.23, tem-se o seguinte problema:

$$\text{Maximizar}_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (2.27)$$

Com restrições:

$$\begin{cases} \alpha_i \geq 0, i = 1, \dots, n \\ \sum_{i=1}^n \alpha_i y_i = 0 \end{cases} \quad (2.28)$$

Essa é chamada a fórmula dual do problema de otimização que possui restrições mais simples e é definida em função dos dados de treinamento e dos rótulos (LORENA; CARVALHO, 2007).

Os vetores de suporte são pontos em que a restrição dada pela Equação 2.22 é igual à unidade e seus  $\alpha$  correspondentes são diferentes de 0 e são utilizados para a definição do separador ótimo.

Os *Kernels*, funções utilizadas para separação não-linear através da transformação de dados em um novo espaço de características, são incluídos na fórmula de otimização da seguinte maneira:

$$\text{Maximizar}_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (\phi(x_i) \cdot \phi(x_j)) \quad (2.29)$$

Dentre as funções de Kernel  $\phi$  disponíveis, nesse estudo usa-se o RBF, do inglês *Radial Base Function*, função de base radial que é bastante explorada em problemas de reconhecimento de padrões e é definida por:

$$R(x_i, x_j) = e^{-\gamma(x_i - x_j)^2} \quad (2.30)$$



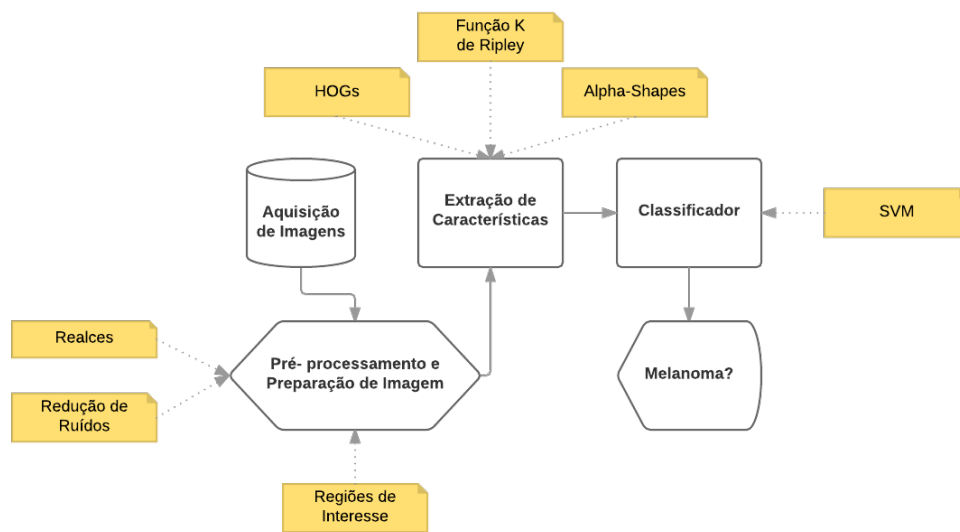
onde  $\gamma$  representa um parâmetro regulador de complexidade, informado a priori pelo usuário.

Neste Capítulo, foram apresentados conceitos referentes às principais técnicas utilizadas na metodologia deste estudo, como suavização de ruídos com filtro gaussiano; realces de regiões com equalização de histograma e transformação logarítmica; extração de características com HOG, função K de Ripley e Alpha-Shapes; e o algoritmo de aprendizado de máquina SVM. A seguir, é descrito o passo-a-passo da metodologia utilizada, expondo os parâmetros utilizados em cada técnica e as medidas adotadas para a fase de treinamento e classificação.

## 3 Metodologia

Para a metodologia de diagnóstico de câncer de pele usando imagens, propõe-se o processo apresentado na Figura 19. O diagrama mostra a utilização de um banco de dados que passará por um pré-processamento, seguido pela fase de extração de características, cujos vetores serão utilizados para treinamento do classificador SVM.

Figura 19: Fluxograma do Modelo de Classificação



Fonte: Elaborada pelo autor

Nas demais subseções, destacam-se as atividades realizadas em cada uma das etapas.


### 3.1 Aquisição de Imagens

Foi utilizado o banco de dados da organização de Colaboração Internacional de Imagens de Pele (ISIC - *International Skin Imaging Collaboration*) (GUTMAN et al., 2016) que é uma ação mundial para melhoria do diagnóstico de melanomas, patrocinado pela Sociedade Internacional para Imagens Digitais de Pele (ISDIS - *International Society for Digital Imaging of the Skin*). O banco de dados ISIC possui o maior repositório público disponível para imagens dermatoscópicas de qualidade.

O banco utilizado por este trabalho é composto por 900 imagens dermatoscópicas, sendo 171 da classe melanoma e 729 da classe não-melanoma. O banco é composto também de 900 máscaras binárias, criadas de forma semiautomáticas e com auxílio de especialistas, contendo as regiões de interesses das lesões, como mostra a Figura 20. Por restrição de

tempo, foi utilizado uma sub base da original, selecionada aleatoriamente, 85 melanoma, 130 normais totalizando 215 indivíduos.

Figura 20: Imagem da base ISIC: (a) Dermatoscopia e (b) máscara binária.



Fonte: (GUTMAN et al., 2016)

## 3.2 Pré-Processamento e Preparação da Imagem

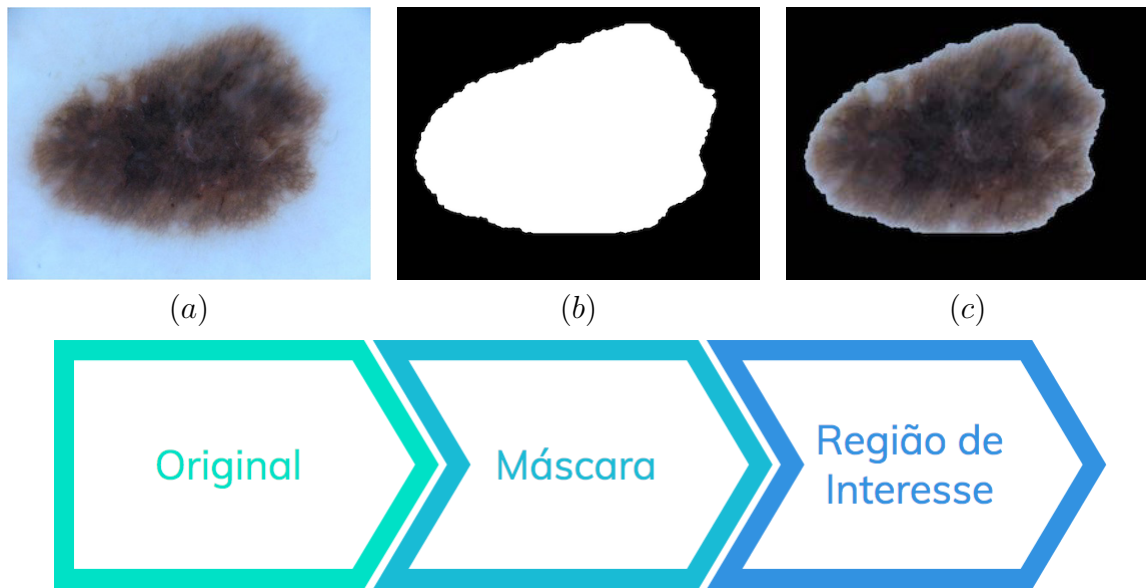
A etapa de pré-processamento consiste em melhorar as feições presentes nas imagens dermatoscópicas que podem apresentar diferentes graus de luminosidade. Os objetivos dessa fase são:

- Separar as regiões de interesses (lesões) do fundo da imagem (pele);
- Minimizar ruídos; e
- Equilibrar os histogramas das imagens a fim de deixá-las mais homogêneas ao longo da base.

Para o estudo, a pele não é relevante ao problema, sendo, portanto, necessária sua extração. Para isso, a base ISIC (GUTMAN et al., 2016) fornece marcações, feitas de forma semiautomáticas, das regiões que contém a lesão de interesse. A primeira ação é aplicar a máscara à imagem dermatoscópica de forma a eliminar a pele e deixar apenas a lesão, como mostra a Figura 21.


Em seguida, é realizada a minimização de ruídos indesejáveis através de um filtro gaussiano como ilustra a Figura 22. Por último, em um teste é utilizada a equalização dos histogramas, em outro o realce logarítmico. Desta forma, busca-se averiguar quais das técnicas melhor auxiliam o processo de reconhecimento proposto por este trabalho.

Figura 21: Preparação: (a) Dermatoscopia (b) máscara binária e (c) região de interesse.



Fonte: Elaborada pelo autor

Figura 22: Minimização de ruídos: (a) Original e (b) após filtro gaussiano.



Fonte: Elaborada pelo autor

### 3.3 Extração de Características

A etapa anterior se faz necessária para preparar as imagens para o processo de extração de características (*features*). Segundo o diagrama da Figura 19, essa fase precede o processo de treinamento, pois, é nesta etapa, que as características são extraídas para serem usadas no classificador. Como extratores de *features* foi proposta a utilização dos descritores de Histograma de Gradientes Orientados, Análise Espacial com função K de Ripley e geometria côncava com *Alpha-Shapes*.

Ao aplicar as técnicas de HOG e Função K de Ripley, três diferentes esquemas de

cores foram utilizadas:

- Esquema monocromático (em escala de cinza);
- Esquema RGB; e
- Esquema HSV.

Em cada esquema foram aplicadas um dos pré-processamentos seguintes: equalização de histograma ou realce logarítmico. Como a imagem em tons de cinza possui apenas um canal, as características foram extraídas de forma direta. No caso dos outros dois esquemas, a imagem possui 3 canais, sendo necessária a separação dos mesmos para que seja realizado o pré-processamento. Em RGB, cada canal foi tratado separadamente e, no final, as características foram concatenadas em um único vetor. Para o sistema HSV, extraiu-se o canal V, onde foi aplicado o pré-processamento, depois os canais foram unidos novamente para, enfim, serem extraídas as características.

### 3.3.1 Descritores HOG

Para computar os descritores HOG das imagens, foram utilizados os seguintes parâmetros que podem ser encontrados na biblioteca do openCV<sup>1</sup> (BRADSKI, 2000):

- *Win\_size*: tamanho de janela de detecção;
- *Block\_size*: tamanho em pixel do bloco;
- *Block\_stride*: bloco de deslize;
- *Cell\_size*: tamanho da célula; e
- *nBins*: número de posições para o histograma.

Foram utilizados diferentes valores para cada parâmetro do descritor HOG. A Tabela 2 mostra o resumo das configurações adotadas.


A janela de detecção foi considerada como o tamanho da região de interesse (lesão). A quantidade de células se refere ao número total de quadrados dividindo a imagem, sendo agrupadas em blocos maiores, contendo 4 células cada um. Em relação aos blocos deslizantes, levou-se em consideração, a sobreposição ou não dos blocos, como ilustra a Figura 23. O retângulo verde representa a janela de detecção, os blocos azuis representam a não sobreposição e os vermelhos mostram a sobreposição de 50% do tamanho do bloco. Quando há sobreposição o número de características aumenta.

<sup>1</sup> Biblioteca aberta para Visão Computacional (VC): <<http://opencv.org/>>

Tabela 2: Quantidade de características geradas para cada configuração do descritor HOG

Esquema	Qtd de Células	Sobreposição	Qtd de Blocos	Bins	Características
Grayscale	16	Não	4	8	128
Grayscale	16	Sim	9	8	288
Grayscale	64	Não	16	8	512
Grayscale	64	Sim	49	8	1568
RGB	16	Não	4	8	384
RGB	16	Sim	9	8	864
RGB	64	Não	16	8	1536
RGB	64	Sim	49	8	4704
HSV	16	Não	4	8	128
HSV	16	Sim	9	8	288
HSV	64	Não	16	8	512
HSV	64	Sim	49	8	1568

Figura 23: Disposição de blocos nas imagens.



Fonte: Elaborada pelo autor

Em todos os testes, o número de posições no histograma de gradiente foi o mesmo. O número de características de cada configuração define o tamanho do vetor gerado para alimentar o algoritmo de reconhecimento.


### 3.3.2 Função K de Ripley

Para a análise de textura através da função K de Ripley, duas abordagens foram aplicadas para caracterizar a área de estudo: uma em círculos e outra em anéis. Um pixel é considerado como um indivíduo e seu valor forma uma determinada espécie, a qual é analisada ao longo de todo o espaço cartesiano que forma a imagem e a área considerada, aplicando a Equação 2.8.

Foram gerados 3 círculos e 3 anéis concêntricos para cada imagem, que passa por

um processo de quantização seguindo os níveis 256, 128, 64, 32, 16 e 8. O comprimento dos raios são ajustados ao tamanho da região suspeita e as medidas de Ripley são calculadas para cada raio, em cada quantização diferente e em cada canal da imagem. Os valores finais são agrupados para formar o vetor de características. Na Figura 24, podem ser observadas as duas abordagens de área usadas neste trabalho.

Figura 24: Função K de Ripley: (a) Área circular e (b) Área em anel.



Fonte: Elaborada pelo autor

Na Tabela 3, são apresentadas as configurações aplicadas em cada teste, bem como o número de características associado. A quantidade de divisões representa o número de círculos ou anéis gerados, enquanto que o total de cores é soma de todos os níveis informados anteriormente  $256 + 128 + \dots + 8$ .

Tabela 3: Quantidade de características geradas para cada configuração da análise de textura.


Esquema (canais)	Área	Qtd de Raios	Total de Cores	Características
Grayscale (1)	Circular	3	504	1512
Grayscale (1)	Aneis	3	504	1512
RGB (3)	Circular	3	504	4536
RGB (3)	Aneis	3	504	4536
HSV (3)	Circular	3	504	4536
HSV (3)	Aneis	3	504	4536

### 3.3.3 Geometria Côncava

Para o método de extração com geometria côncava, espera-se que as neoplasias de pele apresentem diferenças de forma quando comparadas com as imagens de lesões normais (não melanoma), levando em consideração os critérios de Assimetria e Borda da regra ABCD citada no Capítulo 2. Além disso, regiões internas das lesões malignas podem apresentar estruturas não uniformes, mas que representem feridas, enquanto que as

benignas mostrem nenhuma ou quase nenhuma forma interna, como explicado na Figura 25.

Figura 25: Descrição de forma em lesões de pele.



Fonte: Elaborada pelo autor

Primeiramente, deve-se escolher o conjunto de pontos a ser considerado na análise geométrica. Então, define-se como conjunto  $S$  os valores de pixels em tons de cinza encontrados nas regiões de interesse (região que contém a lesão). O conjunto  $S$  é dividido em subpopulações de tonalidades  $P_1, P_2, P_3, \dots, P_n \subset S$ , onde  $n$  é a quantidade de subpopulações usadas. Para limitar o valor de  $n$  a um número pequeno, foi utilizado apenas o esquema de cor *grayscale* para esta abordagem.


Duas restrições são aplicadas na geração de subpopulação: os conjuntos são disjuntos e a quantidade de indivíduos em cada população é a mesma.

Portanto, assume-se que a região de interesse é decomposta em  $N$  subpopulações de mesmas dimensões. Para cada subgrupo gerado (subpopulação de tonalidades), cria-se uma representação binária da distribuição dos pontos na região. Um exemplo dessa decomposição é apresentado na Figura 26. A variação do número de decomposições permite analisar regiões com diferentes tonalidades, mapeadas em formas espaciais diferentes. O processo permite extrair características para cada subpopulação. Como  $N$  é um parâmetro de ajuste, neste estudo utiliza-se uma faixa de 3 a 5 subgrupos.

O contorno côncavo de cada região pode ser analisada através dos  $\alpha$ -*shapes*, bastando apenas que o valor de  $\alpha$  seja informado como parâmetro. Como cada geometria pode apresentar diferentes tamanhos, um único e fixo valor de  $\alpha$  não seria eficiente,



Figura 26: Decomposição de regiões: (a) Região original em tons de cinza, (b) Primeira decomposição, (c) Segunda decomposição e (d) Terceira decomposição.



Fonte: Elaborada pelo autor

optando-se portanto por implementar um  $\alpha$ -adaptativo proposto em (BRAZ JUNIOR et al., 2014). A adaptação leva em consideração o tamanho da janela que envolve a região de interesse de dimensão  $(x, y)$ . O  $\alpha$ -adaptativo é calculado por:

$$\alpha = \frac{\sqrt{xy}}{fa} \quad (3.1)$$

onde  $fa$  é um fator de ajuste para o tamanho máximo de  $\alpha$ , empiricamente definido como 15.


Na Figura 27, são destacados os resultados obtidos ao utilizar o método de geometria côncava. Observe que as estruturas internas são detectadas. Essas regiões internas se tornam um empecilho para o cálculo do perímetro da região como um todo. Para contornar essa situação, todas as bordas são consideradas como perímetro, ou seja, os perímetros internos e externos são somados e considerados como um só.

Caso exista mais de um objeto formado em uma só imagem analisada, são extraídas as medidas de cada objeto separadamente e é calculada a média aritmética para cada métrica. A imagem, portanto, apesar de apresentar várias geometrias, possuirá apenas um valor para cada índice de característica. Após calcular as medidas das geometrias côncavas geradas a cada subpopulação de uma imagem, tem-se o vetor de características que será utilizado para alimentar o algoritmo de reconhecimento de padrões.

### 3.4 Treinamento e Classificação

O algoritmo de aprendizado de máquina, neste estudo, foi treinado primeiramente com 70% e depois com 80% com uma amostra de 215 da base de dados, usando respectivamente 30% e 20% para o processo de testes e validação, mantendo ainda uma proporção de 1:1, ou seja, em um determinado conjunto de treinamento-teste foram utilizados o mesmo

Figura 27: Resultado da aplicação de geometria côncava.



Fonte: Elaborada pelo autor

número de imagens para cada classe (melanoma e não melanoma).

No treinamento com Histogramas de Gradientes Orientados, cada configuração da Tabela 2 foi testada 10 vezes com dada tipo de pré-processamento, gerando um total de 480 testes (12 configurações, 2 proporções, 2 tipos de realces e 10 execuções). Para a função K de Ripley, obteve-se um total de 240 testes (6 configurações, 2 proporções, 2 tipos de realces e 10 execuções). Já para o método de geometria côncava, foram necessários apenas 30 testes (3 subpopulações e 10 execuções cada).

Vale ressaltar que , em cada teste, novos conjuntos aleatórios e disjuntos são gerados para compor o treinamento e a validação. Isso garante estatisticamente generalidade na amostragem das características e dos resultados obtidos. Os valores finais serão apresentados sempre em termos da média e desvio padrão das repetições de cada configuração.

### 3.5 Validação

Para avaliar o classificador em relação à sua capacidade de generalização, os critérios de acurácia, precisão, sensibilidade, especificidade e *f-score* foram analisados para cada configuração escolhida na etapa de extração de características. As fórmulas foram definidas como:

Acurácia:

$$\frac{TP + TN}{TP + TN + FP + FN} \quad (3.2)$$

$$\text{Precisão:} \quad \frac{TP}{TP + FP} \quad (3.3)$$

$$\text{Sensibilidade:} \quad \frac{TP}{TP + FN} \quad (3.4)$$

$$\text{Especificidade:} \quad \frac{TN}{TN + FP} \quad (3.5)$$

$$\text{F-score:} \quad \frac{2 \times TP}{2 \times TP + FP + FN} \quad (3.6)$$

onde TP (*True Positive*) significa os exemplos malignos que foram corretamente classificados como tal, TN (*True Negative*) significa os exemplos benignos corretamente classificados, FP (*False Positive*) e FN (*False Negative*) são respectivamente exemplos benignos classificados incorretamente como malignos e vice-versa. A tabela 4 contém esses conceitos e é chamada de matriz de confusão.

Tabela 4: Matriz de confusão para duas classes.

		Predição	
		Não-melanoma	Melanoma
Classes	Não-melanoma	TN	FP
	Melanoma	FN	TP

Neste Capítulo, foi explanada a metodologia abordada neste estudo, expondo os principais parâmetros utilizados e as medidas fundamentais adotadas para alcançar os objetivos propostos. No próximo Capítulo, os resultados obtidos são apresentados individualmente para cada técnica de extração de características e, depois, são comparadas com os alcançados pela literatura.

## 4 Resultados

Este capítulo apresenta os resultados alcançados após aplicar a metodologia proposta neste trabalho em relação à base de imagens dermatoscópicas em estudo. Os testes foram realizados usando diferentes configurações para avaliar o comportamento e robustez da metodologia.

O teste inicial foi realizado com características extraídas pela técnica de Histogramas de Gradientes Orientados. Na Tabela 5, são apresentados os 5 melhores resultados médios para cada esquema de cores (*Grayscale*, *RGB* e *HSV*) e porcentagem de treinamento (70% e 80%). Na coluna de configuração (Config), são mostrados 3 valores: O primeiro significa o número de células, o segundo valor representa a sobreposição ou não de blocos (1 - com sobreposição ou 0 - sem sobreposição) e o terceiro é o tipo de pré-processamento (1 - equalização de histograma e 2 - realce logarítmico). Os valores para as medidas de validação são mostrados por meio da média e do desvio padrão.

Tabela 5: Resultados obtidos através de extração de características com HOG.

Esq	T (%)	Config	Ac	P	E	S	Fs	nSV
GRAY	70%	(16,1,2)	0.75 ± 0.04	0.76 ± 0.07	0.76 ± 0.09	0.74 ± 0.09	0.74 ± 0.05	102.90 ± 5.82
		(16,0,1)	0.67 ± 0.03	0.73 ± 0.09	0.76 ± 0.11	0.58 ± 0.05	0.64 ± 0.02	99.80 ± 5.51
		(64,0,2)	0.65 ± 0.08	0.72 ± 0.12	0.82 ± 0.09	0.48 ± 0.12	0.57 ± 0.12	102.40 ± 8.09
		(64,1,2)	0.68 ± 0.06	0.71 ± 0.08	0.76 ± 0.09	0.60 ± 0.10	0.64 ± 0.08	110.10 ± 6.52
		(16,1,1)	0.69 ± 0.07	0.71 ± 0.08	0.72 ± 0.09	0.66 ± 0.09	0.68 ± 0.08	97.30 ± 9.21
	80%	(64,0,2)	0.72 ± 0.06	0.81 ± 0.10	0.85 ± 0.10	0.59 ± 0.08	0.68 ± 0.07	125.30 ± 2.79
		(64,1,2)	0.71 ± 0.06	0.76 ± 0.09	0.79 ± 0.10	0.62 ± 0.12	0.68 ± 0.08	126.30 ± 3.20
		(16,0,2)	0.66 ± 0.08	0.72 ± 0.11	0.78 ± 0.14	0.54 ± 0.11	0.61 ± 0.09	110.30 ± 9.27
		(16,1,2)	0.72 ± 0.08	0.71 ± 0.07	0.71 ± 0.07	0.73 ± 0.12	0.72 ± 0.09	111.40 ± 6.47
		(16,0,1)	0.65 ± 0.08	0.69 ± 0.11	0.75 ± 0.12	0.55 ± 0.10	0.61 ± 0.09	109.10 ± 4.04
RGB	70%	(64,0,2)	0.71 ± 0.08	0.76 ± 0.09	0.80 ± 0.10	0.63 ± 0.13	0.68 ± 0.10	112.00 ± 3.66
		(64,1,2)	0.67 ± 0.06	0.72 ± 0.09	0.77 ± 0.12	0.57 ± 0.09	0.63 ± 0.07	101.00 ± 5.69
		(16,0,2)	0.64 ± 0.06	0.71 ± 0.07	0.80 ± 0.09	0.48 ± 0.13	0.56 ± 0.11	105.60 ± 4.67
		(16,0,1)	0.64 ± 0.06	0.70 ± 0.09	0.78 ± 0.09	0.50 ± 0.09	0.58 ± 0.08	99.70 ± 6.87
		(16,1,2)	0.69 ± 0.07	0.70 ± 0.06	0.70 ± 0.07	0.68 ± 0.09	0.69 ± 0.07	101.60 ± 8.60
	80%	(64,1,2)	0.73 ± 0.06	0.77 ± 0.09	0.79 ± 0.12	0.66 ± 0.11	0.71 ± 0.07	118.60 ± 8.63
		(16,1,2)	0.69 ± 0.07	0.72 ± 0.09	0.74 ± 0.11	0.65 ± 0.06	0.68 ± 0.06	111.70 ± 6.37
		(16,0,2)	0.67 ± 0.10	0.70 ± 0.10	0.77 ± 0.07	0.57 ± 0.19	0.62 ± 0.16	116.40 ± 9.81
		(64,0,2)	0.66 ± 0.06	0.70 ± 0.07	0.74 ± 0.12	0.58 ± 0.16	0.62 ± 0.10	121.40 ± 7.17
		(64,1,1)	0.69 ± 0.09	0.68 ± 0.11	0.61 ± 0.18	0.76 ± 0.14	0.71 ± 0.08	127.60 ± 9.15
HSV	70%	(64,1,1)	0.66 ± 0.06	0.70 ± 0.09	0.73 ± 0.12	0.60 ± 0.10	0.64 ± 0.07	115.30 ± 2.37
		(64,0,1)	0.63 ± 0.03	0.65 ± 0.06	0.68 ± 0.11	0.58 ± 0.09	0.61 ± 0.04	107.10 ± 5.92
		(64,1,2)	0.60 ± 0.05	0.64 ± 0.10	0.66 ± 0.15	0.54 ± 0.10	0.57 ± 0.06	110.80 ± 7.88
		(64,0,2)	0.60 ± 0.05	0.63 ± 0.08	0.66 ± 0.12	0.54 ± 0.05	0.58 ± 0.04	108.50 ± 5.20
		(16,0,1)	0.59 ± 0.07	0.61 ± 0.07	0.72 ± 0.08	0.46 ± 0.12	0.52 ± 0.10	106.90 ± 4.95
	80%	(16,0,1)	0.62 ± 0.06	0.66 ± 0.07	0.74 ± 0.12	0.50 ± 0.14	0.56 ± 0.09	119.30 ± 7.47
		(64,0,2)	0.62 ± 0.10	0.66 ± 0.12	0.74 ± 0.13	0.51 ± 0.16	0.56 ± 0.13	124.80 ± 6.08
		(64,1,1)	0.64 ± 0.04	0.66 ± 0.08	0.66 ± 0.15	0.61 ± 0.12	0.62 ± 0.05	123.20 ± 8.89
		(64,1,2)	0.61 ± 0.06	0.65 ± 0.08	0.72 ± 0.11	0.51 ± 0.09	0.56 ± 0.07	121.70 ± 7.63
		(16,1,1)	0.62 ± 0.06	0.64 ± 0.08	0.66 ± 0.11	0.58 ± 0.04	0.60 ± 0.05	110.30 ± 6.31

Os resultados foram ordenados pela precisão (P) , especificidade (E), sensibilidade

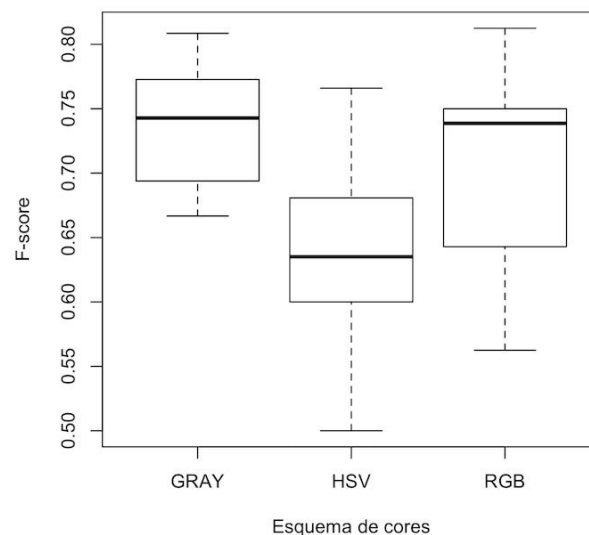
(S) e acurácia (Ac). A melhor configuração apresentou precisão de 81% alcançada por (64,0,2), com imagens divididas em 80% para treino e 20% para teste, usando o esquema de cores *GRAY*. Isso significa que, das imagens classificadas como melanoma, 81% da predição foi correta. Por outro lado, para essa mesma configuração, a sensibilidade foi de 59%, implicando que apenas um pouco mais da metade das imagens de câncer de pele foram classificadas como tal. Para um bom classificador o que se busca é equilibrar essas duas medidas, calculando seu *F-score* (Fs), que, neste caso, foi de 68%.

A configuração (16,1,2), para o esquema *GRAY* e porcentagem 70%, apresenta o melhor *F-score* (74%), equilibrando precisão (74%) e sensibilidade (76%) e superando a acurácia da configuração (64,0,2) em 3%. O número de vetores de suporte (nSV) para (16,1,2) ainda foi menor do que o de (64,0,2), que indica menos super-ajuste na fase de treinamento e maior capacidade de generalização.

Vale ressaltar que, na configuração (16,1,2), foram utilizadas 16 células agrupadas em 4 blocos com sobreposição, gerando um total de 1568 características. Em (64,0,2), 64 células foram agrupadas em 8 blocos sem sobreposição, obtendo um total de 2048 características. Ambas utilizaram realce logarítmico, sendo a primeira configuração melhor e menos complexa que a segunda.

Em relação ao desempenho das melhores, observe o gráfico de caixa (na Figura 28) gerado em relação ao *F-score* e cada esquema de cores. Pode-se notar que, em média, o esquema HSV não foi favorável para o reconhecimento de padrões, apresentando os piores resultados entre os três esquemas abordados para HOG. Isso indica que o canal de brilho V, usado para efetuar o pré-processamento, não foi uma boa opção para realce das características dos descritores HOG. Os esquemas GRAY e RGB tiveram medianas próximas, mas o GRAY foi o que obteve melhor desempenho.

Figura 28: Gráfico de caixa para *F-score* e esquema de cores usando HOG.



Na Tabela 6, são apresentadas as médias dos resultados obtidos com análise espacial através da Função K de Ripley. Os testes foram divididos em três esquemas de cores, como realizado em HOG. Na coluna de configuração, existem dois valores: o primeiro indica o tipo de área utilizada para análise (1 - área circular e 2 - em anéis), enquanto que o segundo valor indica o tipo de realce utilizado (1 - equalização de histograma e 2 - realce logarítmico). Pode-se observar que a melhor configuração foi alcançada pelo esquema HSV ao obter 87% de precisão e 76% de sensibilidade, usando área circular e realce logarítmico no componente V da imagem.

Tabela 6: Resultados obtidos através de análise espacial com Função K de Ripley


Esq	T (%)	Config	Ac	P	E	S	Fs	nSV
GRAY	70%	(1,1)	0.70 ± 0.05	0.81 ± 0.03	0.88 ± 0.03	0.52 ± 0.12	0.63 ± 0.09	110.67 ± 7.36
		(1,2)	0.77 ± 0.07	0.76 ± 0.08	0.75 ± 0.09	0.79 ± 0.08	0.77 ± 0.07	109.00 ± 3.56
		(2,2)	0.78 ± 0.05	0.80 ± 0.07	0.81 ± 0.08	0.75 ± 0.05	0.77 ± 0.05	81.67 ± 7.13
		(2,1)	0.69 ± 0.05	0.76 ± 0.10	0.80 ± 0.12	0.57 ± 0.04	0.65 ± 0.03	113.67 ± 8.96
	80%	(1,1)	0.70 ± 0.01	0.75 ± 0.03	0.80 ± 0.03	0.59 ± 0.00	0.66 ± 0.01	121.00 ± 2.45
		(1,2)	0.70 ± 0.01	0.69 ± 0.02	0.67 ± 0.06	0.73 ± 0.07	0.70 ± 0.03	107.00 ± 14.90
		(2,1)	0.71 ± 0.06	0.79 ± 0.12	0.82 ± 0.13	0.59 ± 0.05	0.67 ± 0.05	136.00 ± 0.00
		(2,2)	0.75 ± 0.03	0.79 ± 0.05	0.80 ± 0.06	0.71 ± 0.00	0.74 ± 0.02	113.33 ± 9.81
RGB	70%	(1,2)	0.74 ± 0.07	0.76 ± 0.11	0.75 ± 0.15	0.73 ± 0.02	0.74 ± 0.04	95.00 ± 4.32
		(1,1)	0.70 ± 0.03	0.70 ± 0.07	0.68 ± 0.12	0.72 ± 0.09	0.70 ± 0.03	96.33 ± 1.25
		(2,1)	0.71 ± 0.07	0.71 ± 0.10	0.69 ± 0.13	0.72 ± 0.03	0.71 ± 0.05	97.33 ± 5.31
		(2,2)	0.69 ± 0.02	0.70 ± 0.00	0.72 ± 0.03	0.67 ± 0.08	0.68 ± 0.05	93.33 ± 4.99
	80%	(1,1)	0.75 ± 0.04	0.75 ± 0.02	0.75 ± 0.03	0.76 ± 0.08	0.76 ± 0.05	103.00 ± 4.32
		(1,2)	0.71 ± 0.02	0.73 ± 0.02	0.75 ± 0.06	0.67 ± 0.10	0.69 ± 0.05	102.33 ± 5.19
		(2,1)	0.72 ± 0.05	0.80 ± 0.08	0.84 ± 0.07	0.59 ± 0.08	0.67 ± 0.06	95.00 ± 8.83
		(2,2)	0.73 ± 0.06	0.74 ± 0.09	0.73 ± 0.14	0.73 ± 0.03	0.73 ± 0.03	113.00 ± 16.31
HSV	70%	(1,2)	0.71 ± 0.03	0.72 ± 0.02	0.75 ± 0.02	0.67 ± 0.08	0.69 ± 0.05	94.33 ± 0.94
		(1,1)	0.61 ± 0.05	0.62 ± 0.06	0.64 ± 0.09	0.57 ± 0.05	0.59 ± 0.04	100.33 ± 3.77
		(2,2)	0.75 ± 0.02	0.74 ± 0.05	0.72 ± 0.09	0.77 ± 0.07	0.75 ± 0.02	101.33 ± 6.13
		(2,1)	0.65 ± 0.05	0.67 ± 0.03	0.71 ± 0.04	0.60 ± 0.12	0.63 ± 0.07	112.33 ± 5.79
	80%	(1,2)	0.82 ± 0.05	0.87 ± 0.05	0.88 ± 0.05	0.76 ± 0.08	0.81 ± 0.05	99.00 ± 9.42
		(1,1)	0.75 ± 0.04	0.84 ± 0.13	0.84 ± 0.15	0.65 ± 0.08	0.72 ± 0.02	115.67 ± 6.94
		(2,2)	0.76 ± 0.00	0.80 ± 0.03	0.82 ± 0.05	0.71 ± 0.05	0.75 ± 0.01	111.67 ± 4.64
		(2,1)	0.73 ± 0.05	0.69 ± 0.04	0.65 ± 0.05	0.80 ± 0.07	0.74 ± 0.05	122.00 ± 3.56

Comparando as melhores configurações dos diferentes esquemas para a abordagem de Ripley, o HSV apresentou o melhor resultado e mediana mais alta, o esquema RGB mostrou limite máximo inferior ao HSV. GRAY mostrou pouca variabilidade, mas com mediana inferior entre todos os esquemas (gráfico apresentado na Figura 29).

O esquema HSV desempenhou melhor resultado no ripley, porque pode codificar melhor as relações de cores ao permitir que as técnicas de realce sejam aplicadas somente sobre os valores de intensidade. Esta abordagem influenciou diretamente na produção de resultados melhores.

Na Tabela 7, são apresentadas as médias dos resultados alcançados com a técnica de extração de características através de geometria côncava. As configurações usadas para testes foram agrupadas por quantidade de subpopulações geradas, neste caso 3, 4 e 5. A configuração Alpha 3 foi a que obteve melhor resultado, apresentando F-score de 99%,

Figura 29: Gráfico de caixa para F-score e esquema de cores usando Função K de Ripley.



100% de taxa de precisão e 98% de sensibilidade. Ou seja, todos os casos previstos pelo classificador como melanoma eram realmente exemplos de câncer pele e, de todos os casos de melanoma presentes nos testes, 98% foram corretamente detectados. A especificidade foi 100%, indicando que, de todos os exemplos de não melanoma apresentados ao classificador, todos foram corretamente rotulados.

Tabela 7: Resultados obtidos usando Alpha Shapes como descritor de forma.

Config	Treino (%)	Ac	P	E	S	Fs	nSV
Alpha 3	70	0,98 ± 0,01	0,99 ± 0,02	0,99 ± 0,01	0,95 ± 0,02	0,97 ± 0,01	26,20 ± 05,50
	80	0,99 ± 0,01	1,00 ± 0,00	1,00 ± 0,00	0,98 ± 0,03	0,99 ± 0,02	28,40 ± 02,19
Alpha 4	70	0,95 ± 0,02	0,98 ± 0,03	0,98 ± 0,02	0,90 ± 0,05	0,94 ± 0,03	57,20 ± 40,43
	80	0,95 ± 0,05	0,98 ± 0,06	0,98 ± 0,03	0,89 ± 0,10	0,93 ± 0,07	40,20 ± 11,32
Alpha 5	70	0,94 ± 0,02	0,98 ± 0,02	0,98 ± 0,01	0,88 ± 0,06	0,93 ± 0,03	30,80 ± 02,95
	80	0,99 ± 0,01	1,00 ± 0,00	1,00 ± 0,00	0,96 ± 0,03	0,98 ± 0,02	65,60 ± 30,09

O pior resultado apresentado pelos  $\alpha$ -shapes foi atingido pela configuração Alpha 5 com 93% de F-score e 88% de sensibilidade que, mesmo assim, foi melhor que as outras duas técnicas de extração de características.

## 4.1 Comparação com Trabalhos Relacionados

A fim de avaliar o desempenho das técnicas aqui propostas, a Tabela 8 apresenta uma comparação dos resultados deste trabalho com os métodos para diagnóstico de melanoma, usando imagens dermatoscópicas, citados na Seção 1.1. Embora os demais trabalhos tenham usado técnicas de reconhecimento de padrões diferentes aplicados à bases de origens e tamanhos distintos, é válido fazer as colocações a seguir.

O método de extração de características com HOG foi o que menos se destacou, levando-se em consideração que, em (BAKHEET, 2017), foram alcançados resultados melhores com a mesma técnica, sendo então necessário realizar um novo teste com a base por eles utilizada. A análise de textura com Ripley apresentou um bom desempenho, tendo em vista que o tamanho das amostras utilizadas na maioria dos trabalhos foram inferiores ao usado neste estudo. Os resultados para *Alpha Shapes* foram os melhores apresentados, salvo a taxa de especificidade de 100% obtido por Rastgo et al. (2016). Faz-se necessária ainda a repetição dos testes com um número maior de imagens e com outras bases, para que se possa realizar uma comparação mais justa e com mais rigor.

Tabela 8: Comparação com trabalhos relacionados.

Trabalho	Características	Classificador	Base (Qtd)	Acc	P	E	S
(SOARES, 2008)	Cor, Fourier e TWP	SVM	- (21)	-	<b>100%</b>	90%	-
(ROSADO, 2009)	Cor, TDE e entropia	kNN	PH <sup>2</sup> (48)	-	-	61%	82%
(ALENCAR, 2015)	Cor e contornos	MLP	PH <sup>2</sup> (50)	86,66%	-	-	-
(PRIYADARSHINI; RENGINI, 2015)	LBP e HOG	SVM	- (20)	-	-	93%	97%
(CODELLA et al., 2015)	<i>Deep Features</i>	SVM	ISIC (2624)	73,9%	-	74,3%	73,8%
(CODELLA et al., 2016)	<i>Deep Features</i>	SVM	ISIC (900)	81%	-	83,2%	72%
(NASR-ESFAHANI et al., 2016)	<i>Deep Features</i>	CNN	UMCG (170)	81%	75%	80%	81%
(RASTGO et al., 2016)	Cor e SIFT	RFs	PH <sup>2</sup> (193)	-	-	90,3%	<b>100%</b>
(ALFED; KHELIFI; BOURIDANE, 2016)	Cor, SIFT e HOG	SVM e kNN	PH <sup>2</sup> (176)	-	-	88,1	91,2%
(BAKHEET, 2017)	HOG	SVM	PH <sup>2</sup> (200)	97,32%	-	96,43%	98,21%
<b>Método Proposto</b>	HOG	SVM	ISIC (215)	75%	76%	76%	74%
<b>Método Proposto</b>	Ripley	SVM	ISIC (215)	82%	87%	88%	76%
<b>Método Proposto</b>	<i>α-shapes</i>	SVM	ISIC (215)	<b>99%</b>	<b>100%</b>	<b>100%</b>	98%

## 4.2 Discussão

Ao analisar os resultados obtidos por cada técnica de extração de características, o HOG obteve menor desempenho em relação aos outros. A desvantagem desse método quanto ao problema proposto se deve ao fato dos histogramas de gradientes orientados não conseguirem mapear de forma eficiente as estruturas referentes a cada classe, ou seja, há confusão entre os gradientes calculados para classe melanoma com os da classe não-melanoma, mesmo trabalhando com diferentes esquemas de cores, apresentando seu maior potencial no esquema de cores em tons de cinza.

De acordo com outros autores, como Priyadarshini e Rengini (2015), o HOG apresenta melhores resultados, quando combinado com outras características. Tendo em vista os aspectos de cores da regra ABCD, esperava-se que o esquema RGB e HSV apresentassem desempenho melhor do que o atingido. Entretanto, essa técnica considera, para cada pixel, o ângulo e a magnitude do maior gradiente entre os três canais, o que prejudica a análise individual das cores.

Por outro lado, ao examinar os resultados da função K de Ripley, verifica-se que o esquema em tons de cinza obteve desempenho muito baixo, enquanto que o HSV demonstrou alto potencial. Neste caso, a técnica analisa os canais separadamente, caracterizando os níveis de intensidade de cada canal com um determinado valor. O esquema RGB, além de



possuir interdependência entre os canais, sofreu pré-processamento em cada canal, que influenciou na cor original. No HSV, apenas o canal de luminosidade foi utilizado para processamento, mantendo a originalidade da cor propriamente dita, o que levou o esquema aos resultados apresentados.


Em relação ao Alpha-Shapes, pôde-se notar que as características extraídas das geometrias determinadas por essa técnica foram as que alcançaram melhores resultados, até mesmo em comparação com outros autores. Isso se deve ao fato dos aspectos de assimetria, borda e diâmetro, previstos na regra ABCD, serem bem caracterizadas com as medidas de geometria circular utilizadas na metodologia. Neste caso, a cor não tomou parte da análise, tendo em vista que apenas o esquema em tons de cinza foi usado.

#### 4.2.1 Estudo de Caso

Quando se trata do processo de aprendizado de máquina, é de fundamental importância verificar o porquê de um dado classificador errar em uma determinada instância da amostra. Essa verificação se faz necessária para identificação de possíveis falhas e melhoria do processo como um todo. Para isso, levou-se em consideração apenas o desempenho do melhor método de extração de características que, neste caso, foi a análise de geometria côncava com alpha-shapes.

Como exemplo para estudo, foram selecionadas duas imagens: uma a qual o classificador acertou e outra cuja predição foi errônea. Na Figura 30, são apresentadas as duas imagens. Em (a) tem-se um exemplo de melanoma classificado com sucesso pelo classificador, enquanto que em (b) é mostrado um exemplo de melanoma equivocadamente classificado como não-melanoma.


Figura 30: Exemplos de caso de sucesso (a) e de falha (b) do classificador.



Fonte: Elaborada pelo autor


Na Figura 31, são apresentados as imagens em tons de cinza (primeira linha) e equalizadas (segunda linha).

Figura 31: Imagens em tons de cinza e equalizadas. (a) Sucesso e (b) falha.



Fonte: Elaborada pelo autor

Figura 32: Geometrias definidas pelo Alpha-Shapes. (a) Sucesso e (b) falha.



Fonte: Elaborada pelo autor

Já na Figura 32, podem ser observadas as geometrias definidas pela técnica alpha-shapes nas duas primeiras quantizações dos níveis de intensidades encontrados nas imagens. No caso de sucesso (a), podemos observar que as bordas são bastante irregulares e as figuras formadas pelo contorno são assimétricas, casando com os aspectos da regra ABCD.

Neste caso, o classificador SVM obteve êxito ao diagnosticar a imagem corretamente.

Por outro lado, ao analisarmos o caso em que houve falha do classificador (b), nota-se bastante simetria. Em virtude disso, o SVM foi levado a diagnosticar equivocadamente a imagem como não-melanoma, resultando em um falso negativo.

Vale ressaltar que, no caso do falso negativo, a forma da lesão não é foi crucial para o diagnóstico correto, tendo que ser levado em consideração também as tonalidades das diferentes pigmentações encontradas na imagem. Fato que não ocorre com a técnica apresentada. Portanto, é importante frisar a combinação duas ou mais técnicas de extração de características como alpha-shapes e função K de Ripley podem melhorar o desempenho do classificador.

Esses foram os resultados obtidos pela metodologia proposta, bem como a discussão e estudo de caso acerca dos valores alcançados. No Capítulo seguinte, apresentam-se as considerações finais após a realização desta pesquisa e expectativas para trabalhos futuros.

## 5 Conclusão

Este trabalho apresentou uma metodologia para detecção de câncer de pele melanoma em imagens dermatoscópicas usando descritores de forma, análise geoestatística e geométrica com intuito de indicar padrões entre malignidade e benignidade de lesões dermatológicas a fim de serem classificadas através de máquinas de vetor de suporte.

A metodologia foi aplicada em uma amostra da base pública de dermatoscopias ISIC, apresentando melhor resultado quando utilizadas as medidas de geometrias côncavas, calculadas com *Alpha Shapes*, como vetor de características. Para essa técnica, foram obtidas precisão de 100% e sensibilidade de 98%. A análise de textura com função K de Ripley mostrou ser promissora, com valores de 87% e 76% para precisão e sensibilidade. Os descritores HOG, apesar de inferiores, também mostraram potencial na tarefa de classificação, alcançando taxa de sensibilidade igual a 76%.

No estudo feito, várias configurações foram testadas repetidas vezes para cada técnica usando duas proporções diferentes na fase de treino do classificador com o intuito de garantir confiabilidade e robustez. Em cada teste, o classificador SVM estimou os melhores parâmetros para as características usadas. Levando-se em consideração esses aspectos, a contribuição consiste em um método de diagnóstico de melanoma usando novas abordagens de extração de características como índices geoestatísticos de ripley e *alpha shapes*, cujos resultados corroboram a viabilidade do uso desses métodos para o problema de classificação de neoplasias malignas da pele.

Vale ressaltar que apenas uma parte da base foi utilizada, não permitindo a completa comparação do método proposto com o estado da arte. Além disso, não foi utilizada nenhum método de seleção e redução de características e, por conseguinte, houveram testes com um alto número de descritores que talvez não fossem cruciais para distinguir uma classe da outra, levando ao aumento da complexidade do classificador. Dado o exposto, faz-se necessário estender o desenvolvimento do trabalho com outras atividade:

- Aplicar a metodologia à base ISIC completa e a outras bases utilizadas nos trabalhos relacionados;
- Usar duas ou mais técnicas de extração de características como função K de Ripley e Alpha-Shapes a fim de combinar descritores de textura com geometria;
- Expandir a classificação para mais tipos de neoplasias de pele que envolvam imagens dermatoscópicas;

- Explorar outros métodos de aprendizado de máquina, como redes neurais profundas e estratégias *ensemble*; e
- Implementar uma ferramenta CAD móvel para auxiliar no diagnóstico precoce da doença.

## Referências

- ALENCAR, F. E. S. Desenvolvimento de um sistema para classificação automática de imagens dermatoscópicas para dispositivos móveis. *Universidade do Estado do Rio Grande do Norte, Biblioteca Central Orlando Teixeira, BR-RN*, 2015. Citado 3 vezes nas páginas 17, 18 e 55.
- ALFED, N.; KHELIFI, F.; BOURIDANE, A. Improving a bag of words approach for skin cancer detection in dermoscopic images. In: IEEE. *Control, Decision and Information Technologies (CoDIT), 2016 International Conference on*. Saint Julian's, Malta, 2016. p. 024–027. Citado 3 vezes nas páginas 17, 18 e 55.
- BAKHEET, S. An svm framework for malignant melanoma detection based on optimized hog features. *Computation*, Multidisciplinary Digital Publishing Institute, v. 5, n. 1, p. 4, 2017. Citado 2 vezes nas páginas 18 e 55.
- BISHOP, C. M. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN 0387310738. Citado 2 vezes nas páginas 36 e 38.
- BRADSKI, G. Opencv library. *Dr. Dobb's Journal of Software Tools*, 2000. Citado 2 vezes nas páginas 17 e 44.
- BRAZ JUNIOR, G. et al. *Detecção de Regiões de Massas em Mamografias usando índices de Diversidade, Geoestatística e Geometria Côncava*. Tese (Doutorado) — Universidade Federal do Maranhão, 2014. Citado 6 vezes nas páginas 23, 27, 31, 32, 36 e 48.
- CODELLA, N. et al. Deep learning, sparse coding, and svm for melanoma recognition in dermoscopy images. In: SPRINGER. *International Workshop on Machine Learning in Medical Imaging*. Munich, 2015. p. 118–126. Citado 3 vezes nas páginas 17, 18 e 55.
- CODELLA, N. et al. Deep learning ensembles for melanoma recognition in dermoscopy images. *arXiv preprint arXiv:1610.04662*, Munich, 2016. Citado 3 vezes nas páginas 17, 18 e 55.
- DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: IEEE. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. USA, 2005. v. 1, p. 886–893. Citado 2 vezes nas páginas 29 e 30.
- DAWSON-HOWE, K. *A Practical Introduction to Computer Vision with OpenCV*. 1st. ed. New Delhi, India: Wiley Publishing, 2014. ISBN 1118848454, 9781118848456. Citado na página 24.
- EDELSBRUNNER, H.; MÜCKE, E. P. Three-dimensional alpha shapes. *ACM Trans. Graph.*, ACM, New York, NY, USA, v. 13, n. 1, p. 43–72, jan. 1994. ISSN 0730-0301. Disponível em: <<http://doi.acm.org/10.1145/174462.156635>>. Citado 2 vezes nas páginas 34 e 35.
- FISCHER, K. Introduction to alpha shapes. . 2000. Citado 3 vezes nas páginas 34, 35 e 36.

GIOTIS N. MOLDERS, S. L. M. B. M. J. I.; PETKOV, N. Med-node: A computer-assisted melanoma diagnosis system using non-dermoscopic images. In: UMCG. *Expert Systems with Applications*. Louisiana, 2015. p. 6578–6585. Citado na página 17.

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing (3rd Edition)*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006. ISBN 013168728X. Citado na página 23.

GUTMAN, D. et al. Skin lesion analysis toward melanoma detection: A challenge at the international symposium on biomedical imaging (isbi) 2016, hosted by the international skin imaging collaboration (isic). *arXiv preprint arXiv:1605.01397*, Munich, 2016. Citado 2 vezes nas páginas 41 e 42.

HAASE, P. Spatial pattern analysis in ecology based on ripley's k-function: Introduction and methods of edge correction. *Journal of vegetation science*, Wiley Online Library, v. 6, n. 4, p. 575–582, 1995. Citado na página 31.

HE, K. et al. Deep residual learning for image recognition. *arXiv preprint arXiv:1512.03385*, 2015. Citado na página 17.

INCA. Estimativas 2016: Incidência de câncer no brasil. [Http://www.inca.gov.br/estimativa/2014/](http://www.inca.gov.br/estimativa/2014/). 2016. Citado na página 15.

JR, H. A.; ODOM, R.; JAMES, W. A pele: estrutura básica e função. doenças básicas da pele de andrews: Dermatologia clínica. Editora Manole Ltda., São Paulo/SP, 1995. Citado 3 vezes nas páginas 21, 22 e 23.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. Nevada: Neural Information Processing Systems, 2012. p. 1097–1105. Citado na página 17.

LORENA, A. C.; CARVALHO, A. C. de. Uma introdução às support vector machines. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43–67, 2007. Citado 2 vezes nas páginas 38 e 39.

MARTINS, L. de O. et al. Classification of breast tissues in mammogram images using ripley's k function and support vector machine. In: SPRINGER. *International Conference Image Analysis and Recognition*. Canada, 2007. p. 899–910. Citado na página 31.

MENDONÇA, T. et al. Ph 2-a dermoscopic image database for research and benchmarking. In: IEEE. *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Osaka, 2013. p. 5437–5440. Citado na página 17.

MONTERO, R. S.; BRIBIESCA, E. State of the art of compactness and circularity measures. In: *International mathematical forum*. Bulgaria: Hikari Ltd, 2009. v. 4, n. 25-28, p. 1305–1335. Citado na página 32.

NASR-ESFAHANI, E. et al. Melanoma detection by analysis of clinical images using convolutional neural network. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2016 IEEE 38th Annual International Conference*. Orlando, 2016. p. 1373–1376. Citado 3 vezes nas páginas 17, 18 e 55.

NAUMOVICH, V.; VAPNIK. *Statistical learning theory*. New York: Wiley New York, 1998. v. 1. Citado na página 37.

- PRIYADARSHINI, D.; RENGINI, D. Automatic melanoma detection using local binary pattern and support vector machine. In: INTERNATIONAL JOURNAL OF INNOVATIVE RESEARCH IN COMPUTER AND COMMUNICATION ENGINEERING. India, 2015. Citado 3 vezes nas páginas 17, 18 e 55.
- RASTGO, M. et al. Classification of melanoma lesions using sparse coded features and random forests. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *SPIE Medical Imaging*. California, 2016. p. 97850C–97850C. Citado 2 vezes nas páginas 18 e 55.
- RIPLEY, B. D. Modelling spatial patterns. *Journal of the Royal Statistical Society. Series B (Methodological)*, JSTOR, p. 172–212, 1977. Citado na página 31.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Munich, 2015. p. 234–241. Citado na página 17.
- ROSADO, L. F. C. M. G. Sistema automático para diagnóstico de lesões cutâneas baseado em imagens dermoscópicas. *Universidade do Estado do Rio Grande do Norte, Biblioteca Central Orlando Teixeira, BR-RN*, 2009. Citado 3 vezes nas páginas 17, 18 e 55.
- SOARES, H. B. *Análise e classificação de imagens de lesões da pele por atributos de cor, forma e textura utilizando máquina de vetor de suporte*. Tese (Doutorado) — Universidade Federal do Rio Grande do Norte, 2008. Citado 7 vezes nas páginas 15, 16, 18, 21, 22, 37 e 55.
- SOUSA, J. R. F. d. S. et al. Methodology for automatic detection of lung nodules in computerized tomography images. *Computer methods and programs in biomedicine*, Elsevier, v. 98, n. 1, p. 1–14, 2010. Citado na página 32.