

UNIVERSIDADE FEDERAL DO PIAUÍ
CAMPUS SENADOR HELVÍDIO NUNES DE BARROS
CURSO DE BACHARELADO EM SISTEMAS DE INFORMAÇÃO

NAYARA HOLANDA DE MOURA

**CLASSIFICAÇÃO AUTOMÁTICA DE LESÕES DE PELE USANDO
DESCRITORES DE FORMA, COR E TEXTURA E MÚLTIPLOS
CLASSIFICADORES**

PICOS - PI

2016

NAYARA HOLANDA DE MOURA

CLASSIFICAÇÃO AUTOMÁTICA DE LESÕES DE PELE USANDO DESCRITORES
DE FORMA, COR E TEXTURA E MÚLTIPLOS CLASSIFICADORES

Monografia apresentada ao Curso de Bacharelado em Sistemas de Informação do Campus Senador Helvídio Nunes de Barros, da Universidade Federal do Piauí, como parte dos requisitos necessários para obtenção do grau de Bacharel em Sistemas de Informação.

Orientadora: Prof^a. Ma. Patrícia Medyna Lauritzen de Lucena Drumond.

Coorientador: Prof. Me. Romuere Rodrigues Veloso e Silva.

PICOS - PI

2016

FICHA CATALOGRÁFICA

Serviço de Processamento Técnico da Universidade Federal do Piauí

Biblioteca José Albano de Macêdo

M929c Moura, Nayara Holanda de.

Classificação automática de lesões de pele usando descritores de forma, cor e textura e múltiplos classificadores / Nayara Holanda de Moura.– 2016.

CD-ROM : il.; 4 ¾ pol. (54 f.)

Monografia (Curso Bacharelado em Sistemas de Informação) – Universidade Federal do Piauí, Picos, 2016.

Orientador(A): Prof^a. Ma. Patrícia Medyna Lauritzen de Lucena Drumond

1. Câncer de Pele.
2. Visão Computacional.
3. Processamento Digital de Imagens. I. Título.

CDD 005

CLASSIFICAÇÃO AUTOMÁTICA DE LESÕES DE PELE USANDO
DESCRITORES DE FORMA, COR E TEXTURA E MÚLTIPLOS
CLASSIFICADORES

Nayara Holanda de Moura

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

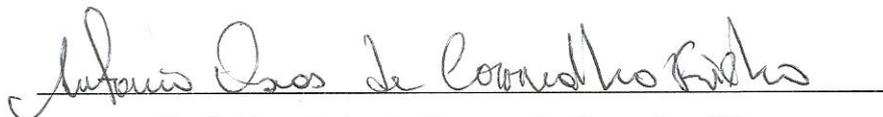
PICOS - PI, 28 / 01 / 2016



Prof^ª. Ma., Patrícia Medyna Lauritzen de Lucena Drumond
Orientadora



Prof^ª. Ma., Alcilene Dalília de Sousa
Membro



Prof. Me., Antonio Oseas de Carvalho Filho
Membro

A Deus,
Por me proteger e me iluminar. Pela sua presença divina no mais íntimo do meu ser. Por criar saídas, quando parece não haver escapatória. Por encher minha alma de riquezas infinitas. Dedico-te, Senhor, minha profissão.

Aos Meus Pais,

Maria de Fátima Holanda Moura e Gerson Raimundo de Moura, que no decorrer da vida, com extenso amor e carinho, ensinaram-me conhecimentos de integridade e perseverança. Muitíssimo obrigada, por me ajudarem na concretização desta formação profissional e por nunca deixarem de acreditar na minha capacidade.

AGRADECIMENTOS

À Deus por guiar meus passos e preencher-me de coragem. Tudo que tenho e tudo que sou devo a ti.

À minha mãe, Maria de Fátima Holanda de Moura, mulher guerreira, amável, delicada e abençoada, que sempre me ensinou a ser correta nas minhas atitudes e forte nas minhas lutas. Um dia espero ser uma mãe tão sublime quanto ela. E ao meu pai, Gerson Raimundo de Moura, que lutou e continua a lutar bastante para dar o melhor aos seus filhos. Ele é fonte de inspiração para que eu alcance novas realizações pessoais e profissionais.

Ao meu irmão, Leonardo Holanda de Moura, que me estimula a estudar e torce pelo meu sucesso. E à minha irmã, Ionara Holanda de Moura, minha melhor amiga e companheira, que sempre me apoia, ajuda e acompanha.

Ao meu namorado, Dayvid Emerson Silva Ferreira, pela ajuda durante este meu último período do curso. Obrigada por todo o apoio que necessitava nos momentos difíceis, todo carinho, amor e respeito, e por tornar minha vida cada dia mais feliz. Te admiro muito!

À Universidade Federal do Piauí – UFPI.

Ao meu orientador, Me. Romuere Rodrigues Veloso e Silva, por me conduzir desde o início da minha formação para o estudo e a pesquisa. Agradeço ainda pela sua paciência, pelos ensinamentos e pelo exemplo de determinação. E à minha orientadora, Ma. Patrícia Medyna Lauritzen de Lucena Drumond, por estar sempre à disposição, me ajudando da melhor forma possível.

A todos os meus estimados professores, que transmitiram valiosos conhecimentos. Em especial: Me. Flávio Henrique Duarte de Araújo e Ma. Alcilene Dalília de Sousa, pela dedicação e competência. Obrigada por toda ajuda que me deram!

Aos meus amigos do curso, Wallinson de Lima Silva, Maíla de Lima Claro e Maria Jaqueline Carvalho de Moura, por seguirem junto comigo nessa caminhada, dividindo alegrias e sofrimentos. Sei que nossa amizade ultrapassará a colação de grau.

A todos vocês, muito obrigada!

"Apesar dos nossos defeitos, precisamos enxergar que somos pérolas únicas no teatro da vida e entender que não existem pessoas de sucesso e pessoas fracassadas. O que existem são pessoas que lutam pelos seus sonhos ou desistem deles."

(Augusto Cury)

RESUMO

O câncer de pele é o mais comum de todos os tipos de câncer e encontra-se entre os principais tipos de lesões de pele. O diagnóstico precoce dessa doença proporciona ao paciente uma maior chance de cura. Neste cenário, métodos computacionais para processamento e análise de imagens de lesão de pele têm sido estudados e desenvolvidos para auxiliar os profissionais da área médica. Esses métodos visam possibilitar ao paciente uma facilidade e rapidez em relação ao diagnóstico da patologia através da interpretação de imagens médicas. As características da lesão são extraídas a partir dessas imagens, para posterior classificação das mesmas, e o resultado dependerá de maneira fundamental da qualidade da etapa de extração. Este trabalho teve como objetivo o desenvolvimento de um método para extração de características em imagens de lesão de pele. Para tanto, o mesmo foi dividido em quatro experimentos, onde o melhor resultado alcançou uma taxa de acerto igual a 94% e um índice Kappa igual a 0,81.

Palavras-chave: Câncer de Pele. Visão Computacional. Processamento Digital de Imagens.

ABSTRACT

Skin cancer is the most common of all cancers, and it is among the main kind of skin lesions. Early diagnosis of this disease gives the patient a better chance of healing. In this scenario, computational methods for processing and analyzing images of skin lesions have been studied and developed to assist medical professionals. These methods are designed to allow the patient an ease and speed in the diagnosis by medical image interpretation. The lesion characteristics are extracted from these images, for later classification of the same, and the result depends in a fundamental way from the extraction stage quality. This work aimed to develop a method for feature extraction in skin lesion images. To this end, it has been divided into four experiments, where the best result achieved an accuracy rate of 94% and a Kappa index of 0.81.

Keywords: Skin cancer. Computer Vision. Digital Image Processing.

LISTA DE ILUSTRAÇÕES

Figura 1	- Imagens de lesões de pele. (a) Nevo comum; (b) Máscara binária da lesão; (c) Melanoma; (d) Máscara binária da lesão ..	22
Figura 2	- Componentes do modelo de cores RGB. (a) Componente R; (b) Componente G; (c) Componente B	23
Figura 3	- Componentes do modelo de cores HSV. (a) Componente H; (b) Componente S; (c) Componente V	23
Figura 4	- Componentes do modelo de cores CMY. (a) Componente C; (b) Componente M; (c) Componente Y	24
Figura 5	- Componentes do modelo de cores $L^*u^*v^*$. (a) Componente L; (b) Componente u; (c) Componente v	24
Figura 6	- Componentes do modelo de cores YCbCr. (a) Componente Y; (b) Componente Cb; (c) Componente Cr	24
Figura 7	- Coloração artificial de uma imagem de lesão de pele	27
Figura 8	- Borda da lesão	27
Figura 9	- Exemplo de cálculo do descritor LBP. (a) Exemplo de janela; (b) Limiarização baseada no pixel central; (c) Padrão calculado a partir do resultado da limiarização	29
Figura 10	- Fluxograma do Experimento 1	35
Figura 11	- Fluxograma do Experimento 2	36
Figura 12	- Fluxograma do Experimento 3	37
Figura 13	- Fluxograma do Experimento 4	38

LISTA DE TABELAS

Tabela 1	- Nível de precisão da classificação, de acordo com o índice Kappa	34
Tabela 2	- Melhores resultados para o modelo de cores RGB	39
Tabela 3	- Melhores resultados para o modelo de cores HSV	40
Tabela 4	- Melhores resultados para o modelo de cores CMY	40
Tabela 5	- Melhores resultados para o modelo de cores L^*u^*v	40
Tabela 6	- Melhores resultados para o modelo de cores YCbCr	41
Tabela 7	- Resultados para o classificador SVM	42
Tabela 8	- Resultados para o classificador MLP	42
Tabela 9	- Resultados para o classificador <i>Random Forest</i>	42
Tabela 10	- Resultados para a classificação das imagens de lesão de pele com os descritores ABCD, GLCM e LBP	43
Tabela 11	- Resultados para a classificação das lesões de pele com a combinação dos classificadores: RBF, MLP e <i>Simple Logistic</i> ...	43
Tabela 12	- Resultados para o algoritmo GLCM	44
Tabela 13	- Resultados para o algoritmo GLRLM	44
Tabela 14	- Resultados para o algoritmo HOG	45
Tabela 15	- Resultados para o algoritmo LBP	45

LISTA DE ABREVIATURAS E SIGLAS

A	Acurácia
ABCD	Assimetria, Borda, Cor, Diâmetro
ABCDE	Assimetria, Borda, Cor, Diâmetro, Evolução
ACS	<i>American Cancer Society</i>
AUC	<i>Area Under Curve</i>
CAD	<i>Computer Aided Diagnosis</i>
CIE	<i>International Commission on Illumination</i>
CMY	<i>Cyan, Magenta, Yellow</i>
FN	Falso Negativo
FP	Falso Positivo
GLCM	<i>Grey-Level Co-occurrence Matrix</i>
GLN	<i>Gray Level distribution</i>
GLRLM	<i>Gray Level Run Length Matrix</i>
HGLRE	<i>High Gray Level Run Emphasis</i>
HOG	<i>Histogram of Oriented Gradients</i>
HSI	<i>Hue, Saturation, Intensity</i>
HSV	<i>Hue, Saturation, Value</i>
INCA	Instituto Nacional de Câncer
K	Kappa
K-NN	<i>K-Nearest Neighbors</i>
LBP	<i>Local Binary Pattern</i>
LGLRE	<i>Low Gray Level Run Emphasis</i>
LRE	<i>Long-Run Emphasis</i>
L*u*v	Luminosidade, cromaticidade u, cromaticidade v
MLP	<i>Multi Layer Perceptron</i>
MP	Média de Probabilidades
NN	<i>Nearest Neighbor</i>
PCA	<i>Principal Components Analysis</i>
PDI	Processamento Digital de Imagens
PM	Probabilidade Máxima
PP	Produtos de Probabilidades
RBF	<i>Radial Basis Function</i>

RGB	<i>Red, Green, Blue</i>
RLN	<i>Run Length distribution</i>
ROC	<i>Receiver Operating Characteristic</i>
RP	<i>Run Percentage</i>
SBD	Sociedade Brasileira de Dermatologia
SMC	Sistema de Múltiplos Classificadores
SRE	<i>Short-Run Emphasis</i>
SURF	<i>Speeded Up Robust Features</i>
SVM	<i>Support Vector Machine</i>
TWP	Transformada <i>Wavelet Packet</i>
VN	Verdadeiro Negativo
VM	Votação Majoritária
VP	Verdadeiro Positivo
WHO	<i>World Health Organization</i>
YCbCr	Luminância, cromaticidade da diferença azul, cromaticidade da diferença vermelha

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Objetivo	16
1.2	Organização do Trabalho	16
2	ESTADO DA ARTE	18
2.1	Câncer de Pele	18
2.2	Processamento Digital de Imagens	19
2.3	Trabalhos Relacionados	19
3	MATERIAIS E MÉTODOS	22
3.1	Base de Imagens	22
3.2	Modelos de Cores	22
3.3	Descritores	25
3.3.1	Regra ABCD.....	25
3.3.2	<i>Grey-Level Co-occurrence Matrix</i>	28
3.3.3	<i>Local Binary Pattern</i>	28
3.3.4	<i>Gray Level Run Length Matrix</i>	29
3.3.5	<i>Histograms of Oriented Gradients</i>	30
3.4	Classificadores	30
3.4.1	<i>Multi Layer Perceptron</i>	30
3.4.2	<i>Random Forest</i>	31
3.4.3	<i>LibLINEAR</i>	31
3.4.4	<i>Support Vector Machine</i>	31
3.4.5	<i>Radial Basis Function</i>	32
3.4.6	<i>K-Nearest Neighbors</i>	32
3.4.7	<i>Naive Bayes</i>	32
3.4.8	<i>Simple Logistic</i>	33
3.4.9	Sistema de Múltiplos Classificadores.....	33
3.5	Métodos de Avaliação dos Resultados	33
4	EXPERIMENTOS	35
5	RESULTADOS E DISCUSSÕES	39
5.1	Resultados para o Experimento 1	39
5.2	Resultados para o Experimento 2	41
5.3	Resultados para o Experimento 3	42

5.4	Resultados para o Experimento 4	44
5.5	Discussões	45
6	CONSIDERAÇÕES FINAIS	47
6.1	Trabalhos Futuros	47
6.2	Publicações Obtidas	48
	REFERÊNCIAS	49

1 INTRODUÇÃO

A computação vem avançando em várias áreas distintas, tais como educação, comércio, segurança e saúde. Ela é um importante meio de auxílio na automatização de processos a fim de se chegar ao objetivo desejado, promovendo a simplificação de diversos problemas. Na saúde, ela se destaca por conta dos inúmeros *softwares* criados para auxílio médico, que tem por finalidade auxiliar na detecção e diagnóstico de doenças.

Os *softwares* médicos são de grande ajuda pois aliviam em muito as limitações do olho e do cérebro humano, como fadiga e distração. Com esses avanços da tecnologia da computação, diversos tipos de Diagnósticos Assistidos por Computador (CAD - *Computer Aided Diagnosis*) têm sido desenvolvidos nos últimos anos. Os sistemas CAD ajudam a equipe médica na interpretação de imagens e, conseqüentemente, proporcionam uma “segunda opinião” (VERAS, 2011). Eles são compostos, em geral, por três etapas: segmentação da estrutura de interesse, extração de características da região segmentada, e classificação da imagem baseada nas características extraídas.

A detecção automática do câncer de pele, por exemplo, é feita a partir da análise de imagens obtidas através do exame de dermatoscopia, com o aparelho dermatoscópico, ou de fotografias tiradas utilizando câmeras digitais convencionais. Para obter-se um diagnóstico das lesões de pele de forma mais precisa, algumas características visuais podem ser observadas, como Assimetria, irregularidade da Borda, variação da Cor interna e o Diâmetro, características essas conhecidas como a regra ABCD (BARCELOS; BOAVENTURA; SILVA JÚNIOR, 2003). Além dessa regra, outros descritores como cor, forma e textura podem ser utilizados nessas metodologias.

O câncer de pele é o mais comum de todos os tipos de câncer e o aumento da sua incidência, em parte, está relacionado ao comportamento das pessoas em relação à exposição ao sol (SBD, 2015). Contudo, é uma doença que tem cura se diagnosticada em seus estágios iniciais. O melanoma, por exemplo, representa menos de dois por cento dos casos de câncer de pele, mas possui o pior prognóstico e o mais alto índice de mortalidade (ACS, 2015).

De acordo com o *Skin Cancer Foundation* (2015), em 2015, foi estimado que 9.940 pessoas morreriam de melanoma. Além disso, cerca de 3 milhões de câncer

de pele não-melanoma e 132.000 melanomas são descobertos a cada ano (WHO, 2015). Desse modo, metodologias computacionais de detecção do câncer de pele podem ser utilizadas para auxiliar no diagnóstico da doença de forma ágil.

O presente trabalho consistiu em uma análise comparativa entre descritores na extração de características, através de distintos experimentos, a fim de atingir um melhor resultado na classificação de lesões de pele. Desse modo, os algoritmos utilizados foram: regra ABCD (Assimetria, Borda, Cor, Diâmetro), *Grey-Level Co-occurrence Matrix* (GLCM), *Local Binary Pattern* (LBP), *Gray Level Run Length Matrix* (GLRLM) e *Histogram of Oriented Gradients* (HOG). Tais experimentos envolveram diversos modelos de cores em que as imagens de lesão de pele foram analisadas. São eles, o modelo de cores RGB (*Red, Green, Blue*), HSV (*Hue, Saturation, Value*), CMY (*Cyan, Magenta, Yellow*), L^*u^*v (*Lightness, chromaticity u, chromaticity v*) e YCbCr (*Luminance, Chroma: blue, Chroma: red*).

1.1 Objetivo

O objetivo desse trabalho é desenvolver um método de visão computacional para a extração de características de imagens de lesão de pele.

1.2 Organização do Trabalho

O presente trabalho está organizado em 6 (seis) capítulos. Após a introdução, que apresentou o problema que se pretende resolver e o objetivo, os próximos capítulos estão organizados da seguinte forma:

- Capítulo 2 – Estado da Arte: São apresentados os conceitos relacionados ao câncer de pele e processamento digital de imagens, e os trabalhos da literatura, fornecendo a sustentação teórica da proposição.
- Capítulo 3 – Materiais e Métodos: São apresentados e descritos os materiais e métodos utilizados nesse trabalho.
- Capítulo 4 – Experimentos: São apresentados os experimentos realizados com a base de imagens para o teste dos algoritmos.
- Capítulo 5 – Resultados e Discussões: São apresentados e discutidos os resultados encontrados para cada um dos experimentos.

- Capítulo 6 – Considerações Finais: São apresentadas as considerações finais do trabalho, indicações de trabalhos futuros, e as publicações obtidas em eventos científicos e revistas indexadas.

2 ESTADO DA ARTE

A fim de obter uma concepção clara do problema proposto pelo presente estudo, fez-se necessária a elaboração de conceitos e formulação de ideias sobre o tema, a fim de expor os pressupostos que darão suporte ao mesmo. Para tanto, será disposta a seguir uma alteração sobre os principais itens que circundam a Classificação Automática de Lesões de Pele Usando Descritores de Forma, Cor e Textura e Múltiplos Classificadores.

2.1 Câncer de Pele

Câncer é a denominação para um grupo de mais de 100 doenças que são caracterizadas pelo crescimento desordenado de células; estas se dividem rapidamente, invadindo tecidos e órgãos, podendo ainda se espalhar para outras regiões do corpo. Por serem muito agressivas e incontroláveis, levam à formação de neoplasias malignas (acúmulo de células cancerosas) (INCA, 2015).

O câncer de pele é o tipo de câncer mais incidente na população. Contudo, é uma doença que tem cura se diagnosticada logo no início. Para a detecção desta patologia, inicialmente os especialistas fazem uma inspeção visual das manchas ou feridas da pele, verificando se aparentam com feridas que não cicatrizam, se possuem crescimento assimétrico, bordas não delimitadas, entre outros aspectos. Entretanto, podem ser realizados alguns exames complementares para verificar seu estágio, como raio X, biópsia e exames de sangue (LACY; ALWAN, 2013).

Existem três tipos de câncer de pele: Carcinoma Basocelular, Carcinoma Espinocelular e Melanoma. O primeiro é o mais prevalente dentre os tipos de câncer. O segundo manifesta-se nas células escamosas, que compõem a maior parte das camadas superiores da pele e é o segundo mais predominante. Já o melanoma é o tipo menos frequente entre eles, mas possui o pior prognóstico e o mais alto índice de mortalidade (SBD, 2015). No Brasil, por exemplo, em 2014, segundo o Instituto Nacional de Câncer (INCA) (2015), foram estimados 188.020 novos casos.

2.2 Processamento Digital de Imagens

Uma imagem pode ser definida como uma função bidimensional $f(x, y)$, onde x e y representam as coordenadas espaciais e f é a informação de cor daquele ponto. Atualmente, técnicas de processamento digital de imagem são aplicadas nas mais diversas áreas, como, por exemplo, exploração espacial, radiologia, previsão do tempo e nanotecnologia (RUSS, 2011).

O Processamento Digital de Imagens (PDI) vem ao longo do tempo se desenvolvendo e auxiliando várias áreas da ciência a extrair informações de imagens. Como se pode observar, por exemplo, em imagens de satélite e, com ênfase nesse trabalho, em imagens médicas. Ele permite viabilizar aplicações em duas diferentes categorias. A primeira é o aprimoramento de informações pictóricas para interpretação humana. E a segunda, é a análise automática por computador de informações extraídas de uma cena (MARQUES FILHO; VIEIRA NETO, 1999).

O PDI é a manipulação de imagens através de computadores onde a entrada e a saída do processo são imagens. Ele tem por objetivo o fornecimento de técnicas para facilitar a identificação e a extração de características encontradas na imagem, para uma posterior interpretação/classificação. Assim, com a utilização de algoritmos de PDI, várias técnicas para detecção automática de patologias se concretizaram.

2.3 Trabalhos Relacionados

A extração de características pode ser considerada uma etapa crucial em sistemas de detecção automática de patologias. O motivo disso é que dependendo da qualidade dos atributos extraídos, a classificação das imagens poderá ser totalmente comprometida. Seu objetivo é descrever a região de interesse da imagem em um formato apropriado para o processamento subsequente, a classificação (GONZALEZ; WOODS, 2010).

Nesse sentido, muitas pesquisas podem ser encontradas na literatura, com o objetivo de atingir melhores resultados. Para detecção automática do câncer de pele, por exemplo, a extração de características no trabalho de Soares (2008) é baseada na textura, forma e cor da lesão. A Transformada *Wavelet Packet* (TWP) é aplicada para extrair a textura, pois consiste em representar a imagem em diferentes bandas de frequência, com distintas resoluções correspondente a cada escala

(dilatação e contração). Os atributos de forma são calculados através do descritor de Fourier e de descritores regionais. E os descritores de cor são calculados para toda a imagem e para a lesão a partir da média de seus *pixels* utilizando os modelos de cores RGB e HSI (*Hue, Saturation, Intensity*). Nos testes foram utilizadas 122 imagens, e os resultados obtidos foram promissores. Entretanto, para as lesões não-melanoma, houve uma queda na taxa de acerto

Conforme Parolin, Herzer e Jung (2010), a extração de características foi implementada através da utilização da regra ABCDE (Assimetria, irregularidade da Borda, variação da Cor, Diâmetro, Evolução), um método automatizado e não-invasivo. Nos testes foram utilizadas 290 imagens (139 não-melanomas e 151 melanomas). Entretanto, os resultados obtidos não foram muito promissores, atingindo uma acurácia de 82,55%. Este método se mostrou mais eficiente para lesões de pele não-melanoma, onde foi possível reduzir a taxa de falsos negativos para 1,89%.

Araújo *et al.* (2012) propuseram um método de extrair as características da imagem baseado na regra ABCD. A definição da rugosidade é feita a partir da borda extraída, bem como a análise do tamanho da mesma e a quantidade de pontos de inflexão (onde as curvas mudam de côncavas para convexas) presentes. Além disso, o diâmetro, a assimetria e a variação de cores são calculados sob a área lesionada. Este método ainda possui algumas limitações, dentre elas, a pequena quantidade de imagens utilizadas para teste e a sua ineficiência na presença excessiva de pelos.

No trabalho de Cavalcanti, Scharcanski e Baranoski (2013) é apresentada uma nova abordagem para a distinção entre melanomas e nevos atípicos (nevos benignos e não usuais, que podem assemelhar-se ao melanoma). Na diferenciação entre estes dois tipos de lesão de pele, foram utilizadas doze características baseadas na concentração dos dois tipos de melanina, a eumelanina e a feomelanina, em conjunto com a regra ABCD. Neste caso, a característica que pertence à letra D da regra é alterada para estruturas Diferenciais: rede pigmentar, glóbulos e pontos, que caracterizam lesões não-melanoma. Os experimentos foram feitos com um total de 152 imagens (45 nevos atípicos benignos e 107 melanomas). Os resultados obtidos foram animadores, porém, os testes poderiam ter sido feitos com uma base de dados maior.

A extração de características com base em uma nova abordagem para o exame do melanoma é mostrada no trabalho de Fornaciali *et al.* (2014). Os descritores chamados *BossaNova* são utilizados nesse exame. Eles são uma extensão do modelo *BoVW* e são baseados em uma distribuição da distância a palavra-chave. Para obtê-los, são utilizadas duas etapas: codificação e agrupamento. A primeira associa os descritores locais da imagem para o elemento mais próximo da tabela de codificação e a segunda calcula a média desses códigos da imagem e agrupa toda a informação em um vetor de características. Este método atingiu uma área sob a curva ROC (*Receiver Operating Characteristic*) de 0,937 com a utilização de 747 imagens dermatoscópicas, dentre elas, 187 melanomas e 560 lesões de pele benignas.

3 MATERIAIS E MÉTODOS

Neste capítulo, são apresentados e descritos os materiais e métodos utilizados nesse trabalho para a extração de características e classificação de lesões de pele. Dentre eles, a base de imagens, os modelos de cores, os descritores, os classificadores e os métodos de avaliação dos resultados.

3.1 Base de Imagens

A base de imagens utilizada para os testes dos algoritmos nesse trabalho é a PH² (MENDONÇA *et al.*, 2013). Ela é constituída por um total de 200 imagens dermatoscópicas: 80 nevos (manchas) comuns, 80 nevos atípicos e 40 melanomas (tumor maligno). As imagens estão no sistema de cores RGB com uma resolução de 768 x 560 *pixels*.

A Figura 1 mostra imagens de lesões de pele pertencentes à base de imagens PH². Na Figura 1 (a) e (b), são apresentados um nevo comum e sua máscara binária da lesão, respectivamente. E na Figura 1 (c) e (d) um melanoma e sua máscara binária. As imagens foram avaliadas e diagnosticadas por um dermatologista, aspecto esse, fundamental pela escolha dessa base. Cada lesão possui um diretório que contém a imagem dermatoscópica original, bem como a máscara binária da lesão.

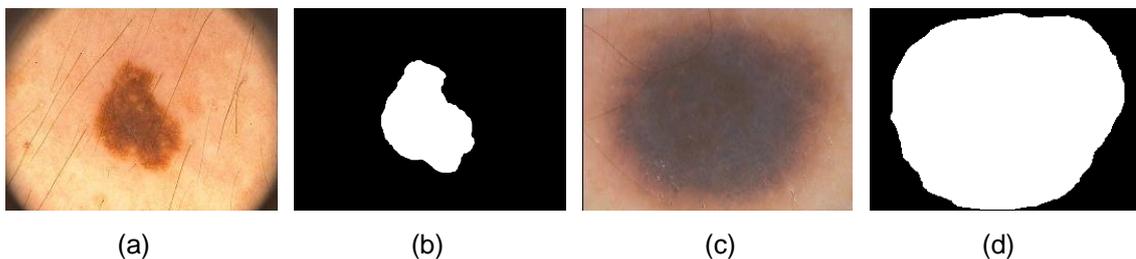


Figura 1 - Imagens de lesões de pele. (a) Nevo comum; (b) Máscara binária da lesão; (c) Melanoma; (d) Máscara binária da lesão.

Fonte: PH² (2013)

3.2 Modelos de Cores

Modelos de cores são uma representação n -dimensional, onde cada pixel da imagem é representado por um ponto que possui, geralmente, três coordenadas.

Seu principal objetivo é a especificação de cores em um formato padronizado. Os modelos de cores utilizados nesse trabalho são apresentados a seguir:

RGB: O modelo de cores RGB representa a cor como uma composição de três cores primárias: vermelho (*Red* – R), verde (*Green* – G) e azul (*Blue* – B). A partir de diferentes intensidades nelas, todas as outras cores são formadas. Os valores de cada componente variam de 0 à 255. Um aspecto importante deste modelo é que ele descreve o comportamento da cor em raios luminosos de forma minuciosa. Deste modo, ele é um dos modelos mais utilizados atualmente. A Figura 2 mostra os componentes de uma imagem da base de dados PH² no sistema de cores RGB.

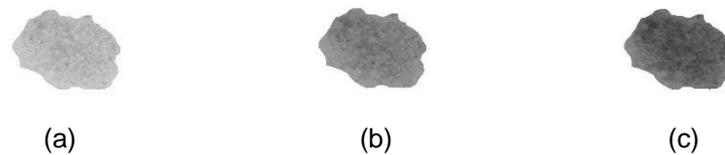


Figura 2 - Componentes do modelo de cores RGB. (a) Componente R; (b) Componente G; (c) Componente B.

HSV: O modelo de cores HSV é definido por três propriedades: matiz (*Hue* – H), saturação (*Saturation* – S) e valor (*Value* – V). Elas são mais “visíveis” e intuitivas para os humanos. O matiz identifica o tipo de cor desde o vermelho até o violeta e mais o magenta, podendo atingir valores de 0 a 100%. A saturação também conhecida como “pureza”, pode atingir valores de 0 a 100% e quanto menor é esse valor, mais cinzenta é a cor, mas quanto maior for o valor, mais “pura” é. Por fim, o valor, que define o brilho da cor, também atinge valores de 0 a 100%. A Figura 3 mostra os componentes de uma imagem da base de dados PH² no sistema de cores HSV.

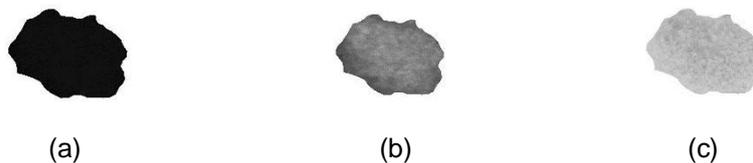


Figura 3 - Componentes do modelo de cores HSV. (a) Componente H; (b) Componente S; (c) Componente V.

CMY: O modelo de cores CMY é o resultado da junção das cores do sistema de cores RGB, ou seja, um modelo complementar. Ele é baseado em três componentes primárias subtrativas: ciano (*Cyan* – C), magenta (*Magenta* – M) e amarelo (*Yellow* –

Y). A Figura 4 mostra os componentes de uma imagem da base de dados PH² no sistema de cores CMY.

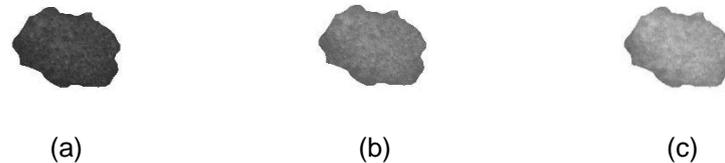


Figura 4 - Componentes do modelo de cores CMY. (a) Componente C; (b) Componente M; (c) Componente Y.

L*u*v: O modelo de cores L*u*v (Lightness, chromaticity u, chromaticity v) é também conhecido como CIELUV. Ele foi definido na tentativa de aumentar a uniformidade das cores percebidas pelo sistema visual humano, em 1976 pela Comissão Internacional de Iluminação (*International Commission on Illumination – CIE*) (FRASER; MURPHY; BUNTING, 2004). O componente L define o valor de luminosidade corrigida para uma escala perceptualmente linear. Já as componentes u e v indicam a cromaticidade da cor. A Figura 5 mostra os componentes de uma imagem da base de dados PH² no sistema de cores L*u*v.

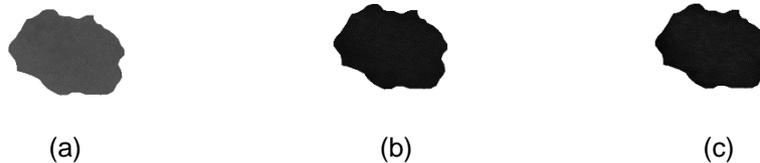


Figura 5 - Componentes do modelo de cores L*u*v. (a) Componente L; (b) Componente u; (c) Componente v.

YCbCr: O modelo de cores YCbCr (luminance, Chroma: blue, Chroma: red) representa as cores como brilho e dois sinais de diferença de cor. Ele é composto por três componentes: luminância (Y), croma da diferença azul (diferença entre o componente azul e um valor de referência) (Cb) e croma da diferença vermelha (diferença entre o componente vermelho e um valor de referência) (Cr). A Figura 6 mostra os componentes de uma imagem da base de dados PH² no sistema de cores YCbCr.

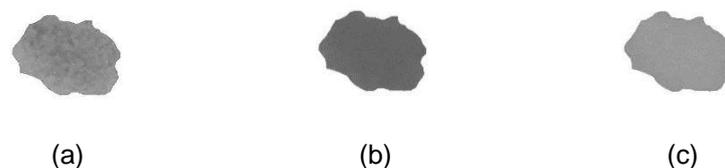


Figura 6 - Componentes do modelo de cores YCbCr. (a) Componente Y; (b) Componente Cb; (c) Componente Cr.

3.3 Descritores

Atributos são propriedades que podem ser mensuradas a partir de uma imagem, como por exemplo forma, cores e texturas. Esses atributos, que geralmente são agrupados em um vetor de escalares, são denominados de descritor de imagem. Neste capítulo, os descritores utilizados para extrair características das imagens são detalhados a seguir.

3.3.1 Regra ABCD

Para obter-se um diagnóstico das lesões de pele, algumas características visuais podem ser observadas, como Assimetria, irregularidade da Borda, variação da Cor interna e o Diâmetro. Desse modo, a regra ABCD é um importante algoritmo para descrever lesões de pele. Cada etapa desse algoritmo é apresentada detalhadamente abaixo:

- **Assimetria:** Lesões que tendem a ser mais arredondadas são geralmente não cancerosas e/ou não malignas. Assim, a assimetria de uma lesão diz respeito à sua forma. Nesse trabalho, ela foi obtida utilizando a Equação 1, que calcula a distância entre um ponto e uma reta (diagonal maior obtida pelo diâmetro). A maior distância entre a reta e um ponto pertencente à borda é armazenada. O resultado, em *pixels*, é utilizado para a classificação.

$$d = \frac{|ax_0 + by_0 + c|}{\sqrt{a^2 + b^2}} \quad (1)$$

onde a , b , c são os coeficientes da reta e x_0 , y_0 os pontos da coordenada da imagem.

- **Irregularidade da Borda:** Nesta etapa, a definição da irregularidade é baseada em pontos de inflexão (picos e vales), onde as curvas mudam de côncavas para convexas, ou vice-versa. Dado que lesões não malignas geralmente possuem bordas lisas e suaves, e já as malignas, bordas irregulares, ela é dividida em duas técnicas. Na primeira técnica, pesos são atribuídos para cada um dos quatro vizinhos da direita e da esquerda de todos os pontos pertencentes à borda da lesão.

O vizinho que estiver abaixo do ponto analisado em relação à coordenada y , recebeu peso 1, caso contrário, recebeu peso -1 (ARAÚJO *et al.*, 2012).

A soma dos pesos dos oito vizinhos determinam uma inflexão. Se esta soma for maior ou igual a 2, ou menor ou igual a -2, o ponto analisado é considerado uma inflexão. Além disso, outro ponto deve ser observado; se essa soma dos pesos for positiva, a inflexão é considerada um pico, mas se negativa, é considerada um vale. Esta primeira técnica obtém a quantidade total de picos e vales menores existentes na borda da lesão (ARAÚJO *et al.*, 2012).

Na segunda técnica, é utilizada a equação do produto vetorial (Equação 2) com a finalidade de encontrar os picos e os vales maiores da lesão. Esta equação é empregada para todos os pontos pertencentes à borda da lesão, considerando os seus vizinhos da direita e esquerda ($p - 15$; p ; $p + 15$), sendo p o ponto, ou seja, variação de 15 *pixels* à esquerda e 15 *pixels* à direita do ponto p . Assim, caso o resultado do produto vetorial seja maior que zero, $p_1 = (x_1, y_1)$, $p_2 = (x_2, y_2)$ e $p_3 = (x_3, y_3)$ constituem um pico, porém, se menor que zero, constituem um vale (ARAÚJO *et al.*, 2012).

$$p = (x_2 - x_1) \cdot (y_3 - y_1) - (y_2 - y_1) \cdot (x_3 - x_1) \quad (2)$$

- **Cor:** Essa etapa é responsável pelo cálculo da quantidade de cores presentes na lesão. Isso deve-se ao fato de que o atributo se refere à variação da coloração interna. Geralmente, lesões com cor interna homogênea são não malignas. Já os melanomas, possuem grande variação das intensidades marrom e preta, e podem conter regiões isoladas em branco.

A quantidade de cores utilizada na classificação é calculada através da divisão da imagem em dez intervalos. As cores pertencentes ao mesmo intervalo foram consideradas semelhantes. A contagem do número de *pixels* é feita para cada intervalo, sendo descartados os que possuem regiões muito pequenas (menos de 100 *pixels*) (ARAÚJO *et al.*, 2012).

A Figura 7 mostra um exemplo de como é feito o cálculo da quantidade de cores presentes na lesão de pele. A coloração foi feita artificialmente através da técnica utilizada. Nesse exemplo, foram encontradas 7 (sete) cores diferentes na lesão.

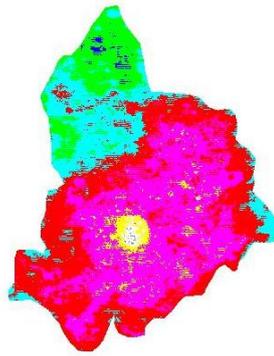


Figura 7 - Coloração artificial de uma imagem de lesão de pele.

• **Diâmetro:** Nessa etapa, a máscara binária é utilizada para obter a borda da lesão com a utilização do algoritmo de Sobel (SOBEL, 1970). O resultado é mostrado na Figura 8. Assim, com a borda encontrada, o diâmetro é calculado. Ele consiste na maior distância entre dois pontos, $p_1 = (x_1, y_1)$ e $p_2 = (x_2, y_2)$ pertencentes à borda de uma imagem, constituindo a diagonal maior. O cálculo dessa distância é feito com a utilização da equação da distância euclidiana (Equação 3).

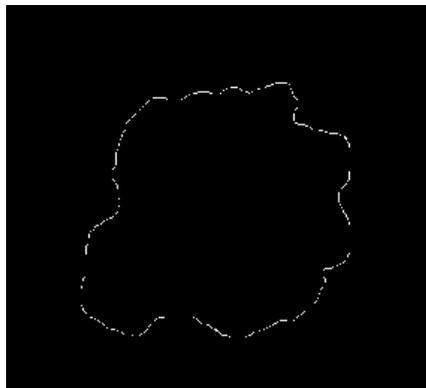


Figura 8 - Borda da lesão.

Lesões malignas tendem a possuir um diâmetro maior ou igual a 6mm com a possibilidade de variação de tamanho e forma. Entretanto, as não malignas normalmente possuem um diâmetro menor que 6mm e não mudam de tamanho. Assim, o diâmetro é um importante atributo a ser calculado. Para a classificação, a distância é utilizada em *pixels*.

$$D_{(p,q)} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (3)$$

3.3.2 *Grey-Level Co-occurrence Matrix*

A *Grey-Level Co-occurrence Matrix* (GLCM) ou, Matrizes de Co-ocorrências de Níveis de Cinza, é uma técnica que tem como base a análise de textura em imagens. Nela é analisada as co-ocorrências existentes entre pares de *pixels* através de algum padrão. Uma GLCM é sempre uma matriz quadrada, onde as informações das intensidades relativas dos *pixels* são armazenadas. Por este motivo, as imagens utilizadas são sempre em tons de cinza (HARALICK; SHANMUGAM; DINSTEIN, 1973).

As probabilidades de co-ocorrências são calculadas entre dois níveis de cinza i e j , utilizando uma orientação Θ (*theta*) e uma distância conhecida como *pixel pair spacing*. Essa orientação pode assumir os valores de 0° , 45° , 90° e 135° (BARALDI; PARMIGGIANI, 1995). Para cada relacionamento espacial possível (distância e orientação) existe uma matriz de co-ocorrência. Desse modo, todas as informações sobre a textura de uma imagem estarão contidas nessa matriz.

Haralick, Shanmugam e Dinstein (1973) definiu 14 características significativas para a GLCM. Contudo, a utilização de algumas dessas características pode gerar um melhor desempenho, do que a utilização de todas. Assim, nesse trabalho são feitos cálculos dos seguintes atributos de textura: contraste, correlação, energia, homogeneidade e entropia (SILVA, 2013).

3.3.3 *Local Binary Pattern*

O descritor *Local Binary Pattern* (LBP), ou Padrão Binário Local, apresenta um bom desempenho em várias aplicações como por exemplo, na classificação e na segmentação de textura, e inspeção de superfície (SURULIANDI; MEENA; ROSE, 2012; SILVA; AIRES; VERAS, 2014).

No descritor LBP original (OJALA; PIETIKINEN; HARWOOD, 1996), os *pixels* de uma imagem em níveis de cinza por limiarização são rotulados. A Figura 9 mostra o funcionamento do descritor. O *pixel* central da janela de vizinhança 3×3 constitui o valor do limiar, onde cada *pixel* é comparado com o central. O resultado final, considerado um número binário, é feito para todas as janelas escolhidas da imagem. Além disso, quando todas as janelas forem computadas, o vetor de atributos é montado com a junção dos valores obtidos. Assim, com a limiarização feita, um

histograma da célula é calculado, ou seja, as quantidades de “0” e “1” são calculadas.

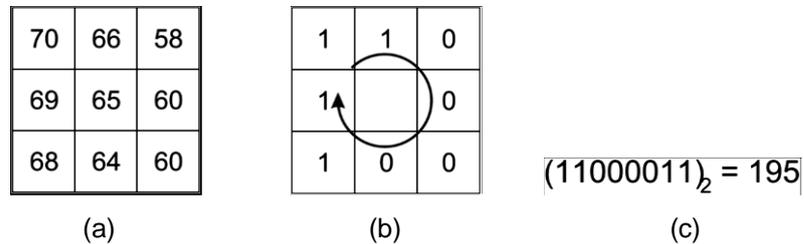


Figura 9 - Exemplo de cálculo do descritor LBP. (a) Exemplo de janela; (b) Limiarização baseada no pixel central; (c) Padrão calculado a partir do resultado da limiarização.

Fonte: Silva (2014)

3.3.4 Gray Level Run Length Matrix

A *Gray Level Run Length Matrix* (GLRLM), método de comprimento de primitiva a nível de cinza, é também uma técnica que tem por objetivo extrair as características de textura em uma determinada imagem. Para isso, ela faz uso de matrizes auxiliares e verifica as repetições dos pixels (primitivas).

Segundo Galloway (1975), a partir da matriz do GLRLM cinco medidas estatísticas podem ser extraídas. São elas, a ênfase em primitivas curtas (*Short-Run Emphasis*) (SRE), a ênfase em primitivas longas (*Long-Run Emphasis*) (LRE), a uniformidade do nível de cinza (*Gray Level distribution*) (GLN), a uniformidade do comprimento da primitiva (*Run Length distribution*) (RLN) e a percentagem de primitivas (*Run Percentage*) (RP). Entretanto, mais duas medidas estatísticas foram determinadas por Chu, Sehgal e Greenleaf (1990), a ênfase em primitivas de baixo nível de cinza (*Low Gray Level Run Emphasis*) (LGLRE) e a ênfase em primitivas de alto nível de cinza (*High Gray Level Run Emphasis*) (HGLRE).

As primitivas são um conjunto colinear maximal de pixels conectados, em que contêm o mesmo tom de cinza. O comprimento, inclinação e nível de cinza as caracterizam. Essa técnica funciona da seguinte forma: uma matriz GLRLM é criada para cada corte e possui o número de primitivas dos níveis de cinza na direção Θ e a uma distância d . Essa orientação pode ser de 0° , 45° , 90° ou 135° . Dessa forma, uma soma de todas as matrizes do GLRLM de cada corte é feita, e a partir do número de repetições encontrados, a matriz é dividida e normalizada.

3.3.5 *Histograms of Oriented Gradients*

O descritor *Histograms of Oriented Gradients* (HOG), ou Histograma de Gradientes Orientados (DALAL; TRIGGS, 2005), calcula o histograma da orientação dos gradientes na imagem. Ele se baseia na ideia que a forma e a aparência de um objeto podem ser descritas muitas vezes pela intensidade dos gradientes ou pela direção das bordas, mesmo sem um conhecimento prévio da posição de tais bordas.

O HOG consiste em converter a imagem para escala de cinzas e normalizá-la de acordo com a iluminação. Além disso, é feita a computação dos gradientes e uma divisão da imagem em pequenas regiões espaciais chamadas células. Para cada célula é calculado um histograma local *1-D* das orientações sobre os pixels da célula (SAID; ATRI; TOURKI, 2011). As células podem ter forma retangular ou radial. Após os histogramas serem computados, eles são normalizados através de um acúmulo de histogramas locais em regiões espaciais um pouco maiores chamadas de blocos.

Os histogramas acumulados são então utilizados para normalizar todas as células naquele bloco. Após a normalização, uma janela de detecção é coletada sobre os histogramas gerados, que consiste na saída do descritor HOG.

3.4 Classificadores

Um classificador tem por objetivo dividir o espaço de características em regiões de decisão, ou seja, os vetores de características que pertencerem à mesma região de decisão irão fazer parte da mesma classe. Neste trabalho, a entrada dos classificadores é o vetor de atributos resultante dos descritores, e a saída é a classe que a região pertence. Os classificadores que foram utilizados são apresentados a seguir.

3.4.1 *Multi Layer Perceptron*

O *Multi Layer Perceptron* (MLP), ou Perceptron de Múltiplas Camadas, é uma rede neural artificial utilizada para resolver problemas mais complexos. Ele possui uma rede de perceptrons dispostos em camada. Seu método mais popular para aprendizado é chamado de retropropagação (*backpropagation*). Esse tipo de aprendizado consiste em dois passos através das diferentes camadas da rede:

propagação e retropropagação. No primeiro, um padrão de atividades é aplicado aos nós sensoriais e a resposta real da rede é produzida. No segundo, os pesos sinápticos são ajustados de acordo com um sinal de erro para ser propagado na direção contrária das conexões sinápticas (HAYKIN, 2008).

3.4.2 *Random Forest*

O classificador *Random Forest* (BREIMAN, 2001) é uma combinação de diversas árvores onde cada uma de suas árvores depende dos valores de um vetor independente aleatoriamente e com a mesma distribuição para todas as árvores da série de árvores de decisão. Por fim, quando um grande número de árvores são geradas, as classes com maior número de votos são eleitas.

3.4.3 *LibLINEAR*

LibLINEAR (FAN *et al.*, 2008) é uma biblioteca de código aberto para classificação linear em grande escala que suporta regressão logística e máquinas de vetor de suporte lineares. Nele, existem vários parâmetros disponíveis para uso avançado. Por exemplo, pode-se especificar um parâmetro para obter saídas de probabilidade para a regressão logística. O *LibLINEAR* tornou-se uma das técnicas de aprendizagem mais promissoras para dados com um grande número de instâncias e recursos.

3.4.4 *Support Vector Machine*

Proposto por Cortes e Vapnik (1995), a *Support Vector Machine* (SVM), ou Máquina de Vetor de Suporte, é uma técnica de aprendizagem supervisionada, que contém as fases de treinamento, atributos e saídas desejadas, e teste, para encontrar uma saída a partir de vetor de entrada. Em geral, é feito um mapeamento do espaço de entrada para um espaço de dimensionalidade maior e calculado, em seguida, um hiperplano de separação ótimo a fim de maximizar a distância de separação entre as classes.

3.4.5 *Radial Basis Function*

O classificador *Radial Basis Function* (RBF), ou Função de Base Radial, possui três camadas. A camada de entrada é formada por nós de fonte (unidades sensoriais) que conectam a rede ao seu ambiente. A segunda camada aplica uma transformação não-linear do espaço de entrada para o espaço oculto. E a camada de saída é sempre linear (HAYKIN, 2008). A transformação do espaço de entrada para um espaço de dimensionalidade maior é utilizada para resolver o problema da classificação e feita de forma não-linear de acordo com o Teorema de Cover (COVER, 1965), ou seja, um problema complexo de classificação, disposto não-linearmente em um espaço de alta dimensão, possui uma probabilidade maior de ser linearmente separável do que em um espaço de dimensionalidade baixa.

3.4.6 *K-Nearest Neighbors*

O *K-Nearest Neighbors* (K-NN), ou K-Vizinhos Mais Próximos, é um algoritmo baseado em memória. Sua fase de treinamento consiste em armazenar todos os padrões de treinamento. O parâmetro K é o número de vizinhos a ser considerado para a classificação. Para $K = 1$, ele é também chamado de método do vizinho mais próximo (*Nearest Neighbor* – NN), que classifica um padrão como pertencente a mesma classe do padrão mais próximo a ele no conjunto de treinamento. Quando $K > 1$, as distâncias do novo padrão são calculadas, considerando os K padrões com as menores distâncias ao padrão a ser classificado como pertencente a classe da maioria dos K padrões mais próximos do conjunto de treinamento (SILVA JÚNIOR, 2007).

3.4.7 *Naive Bayes*

O classificador *Naive Bayes* (MANNING; RAGHAVAN; SCHÜTZE, 2008) se baseia em modelos probabilísticos (Teorema de Bayes). Ele calcula a pontuação de uma classe, ou seja, probabilidade de um objeto ser assinalado à classe, e cria um ranking das classes. O algoritmo classifica o objeto para a classe que ocupa a primeira posição desse ranking.

3.4.8 *Simple Logistic*

O Algoritmo *Simple Logistic* (SUMNER; FRANK; HALL, 2005) é um classificador para construção de modelos de regressão logística lineares. Ele utiliza o *LogitBoost* (LANDWEHR; HALL; FRANK, 2005) com funções de regressão simples para a montagem dos modelos logísticos. O número ideal de iterações *LogitBoost* para executar é através da validação cruzada, o que leva à seleção de atributos automática.

3.4.9 Sistema de Múltiplos Classificadores

Os Sistemas de Múltiplos Classificadores (SMC) são utilizados para combinar os resultados de classificadores. Uma de suas técnicas consiste em uma votação, onde a saída que possuir mais votos será o resultado final do classificador. Outra técnica é utilizar suas taxas de acerto de forma ponderada, atribuindo um peso maior ao classificador que possuir a melhor taxa de acerto (HAYKIN, 2008).

3.5 Métodos de Avaliação dos Resultados

Para avaliar o desempenho dos algoritmos de classificação foram utilizadas algumas métricas conhecidas na literatura: Acurácia (A), área sob a curva ROC (AUC – *Area Under Curve*) e índice Kappa (K) (ROSENFELD; FITZPATRICK-LINS, 1986). Esses métodos de avaliação dos resultados foram calculados a partir da matriz de confusão, composta por 4 valores: O Verdadeiro Positivo (VP) e o Verdadeiro Negativo (VN), que apresentam a quantidade de lesões não-melanocíticas e melanocíticas, respectivamente, classificadas corretamente; e o Falso Positivo (FP) e o Falso Negativo (FN), que apresentam a quantidade de lesões não-melanocíticas e melanocíticas, respectivamente, classificadas incorretamente.

A Acurácia é a porcentagem de casos corretamente classificados em um conjunto de teste. Já a área sob a curva ROC (*Receiver Operating Characteristic* – Curvas de Características de Operação do Receptor), mostram as taxas de verdadeiros positivos em relação às taxas de falsos positivos. Ela avalia a eficiência em termos de taxa de acerto dos classificadores, quanto maior a área melhor o desempenho do classificador.

O nível de precisão do índice Kappa utilizado para a avaliação dos resultados é apresentado na Tabela 1. Ele é utilizado como uma medida apropriada da exatidão por representar inteiramente a matriz de confusão.

Tabela 1 - Nível de precisão da classificação, de acordo com o índice Kappa.

Índice Kappa (K)	Qualidade
$K \leq 0.2$	Ruim
$0.2 < K \leq 0.4$	Razoável
$0.4 < K \leq 0.6$	Bom
$0.6 < K < 0.8$	Muito Bom
$K \geq 0.8$	Excelente

4 EXPERIMENTOS

Neste capítulo, são apresentados e detalhados os experimentos realizados com a base de imagens para o teste dos algoritmos.

Experimento 1: A regra ABCD é utilizada para a extração de características de lesões de pele. O atributo Cor foi testado com os modelos de cores RGB, HSV, CMY, L^*u^*v e YCbCr. Em cada modelo, foram feitos testes com cada componente, com a soma e com a distância euclidiana entre eles (de dois em dois) gerando novos componentes. Para a classificação, foram utilizados os algoritmos MLP, RBF, *Random Forest*, *LibLINEAR*, SVM e K-NN (MOURA *et al.*, 2015a; MOURA; SILVA; ARAÚJO, 2015).

O vetor de atributos, obtido pelo descritor ABCD e utilizado como entrada para os classificadores, é composto por 5 atributos calculados sob as imagens: maior distância entre a reta e um ponto, quantidade total de picos e vales menores, quantidade total de picos e vales maiores, maior distância entre dois pontos e a quantidade de cores encontradas na lesão. Para cada teste, somente o atributo Cor foi modificado nesse vetor, a partir dos sistemas de cores, seus componentes e combinações. A Figura 10 mostra o fluxograma desse experimento (MOURA *et al.*, 2015a; MOURA; SILVA; ARAÚJO, 2015).

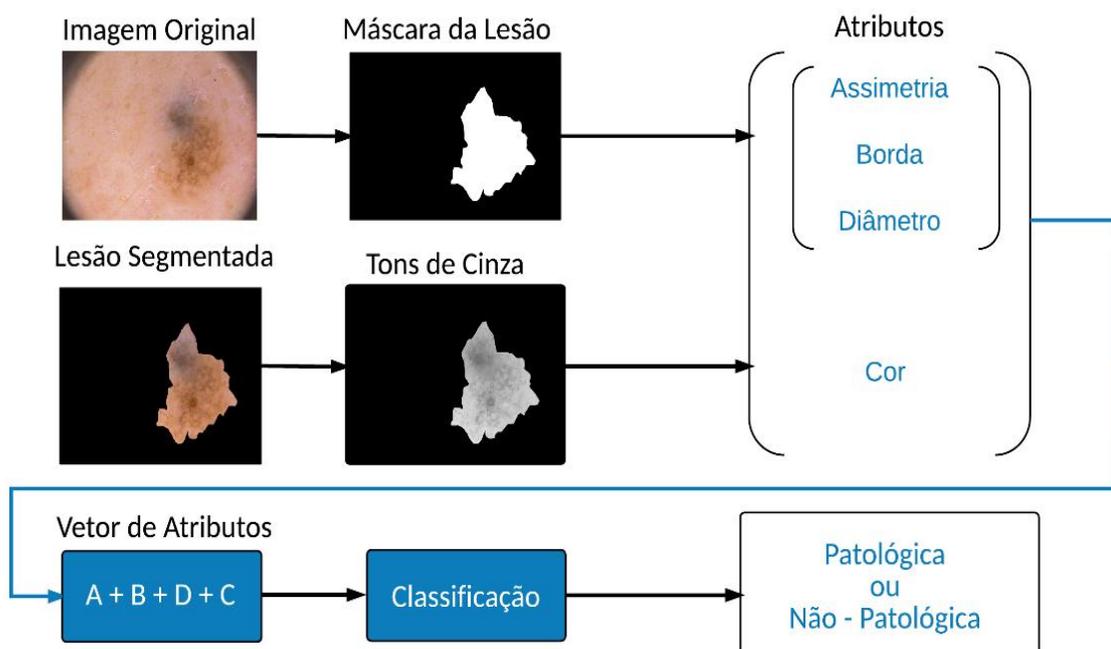


Figura 10 - Fluxograma do Experimento 1.

Experimento 2: A GLCM e somente o atributo Cor da regra ABCD foram utilizados para a extração de características de lesões de pele. Eles foram testados no modelo de cores HSV, por apresentar o melhor resultado do Experimento 1. Os testes foram feitos com cada componente do modelo e a soma entres eles. Para a classificação, foram utilizados os algoritmos MLP, SVM e *Random Forest*. O vetor de atributos utilizado como entrada para os classificadores é composto por 6 atributos calculados sob as imagens: contraste, correlação, energia, homogeneidade, entropia e cor. A Figura 11 mostra o fluxograma desse experimento (MOURA *et al.*, 2015b).

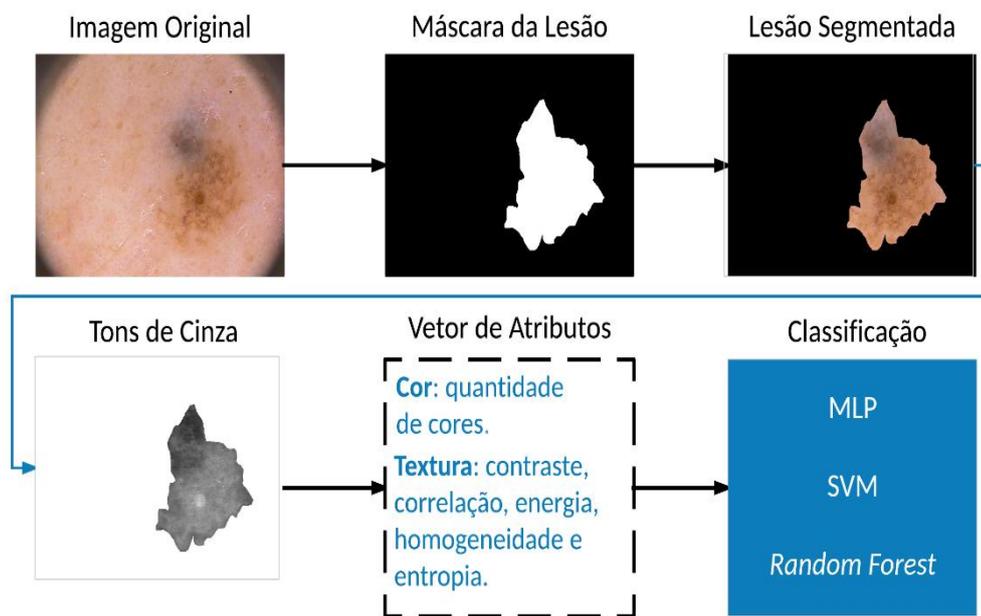


Figura 11 - Fluxograma do Experimento 2.

Experimento 3: Os algoritmos ABCD, GLCM e LBP foram empregados, em conjunto, para a extração de características de lesões de pele com o componente gerado pela soma dos canais de saturação e valor do modelo de cores HSV. Isto porque esse componente se mostrou o que melhor diferenciou as lesões de pele, a partir da análise dos experimentos anteriores. Para a classificação, foram utilizados os algoritmos SVM, MLP, *Random Forest*, K-NN, *Naive Bayes*, RBF, *Simple Logistic* e SMC. A Figura 12 mostra o fluxograma desse experimento (MOURA *et al.*, 2015c).

O vetor de atributos utilizado como entrada para os classificadores é composto, no total, por 278 características calculadas sob as imagens. O descritor ABCD calculou 5 dessas características: maior distância entre a reta e um ponto, quantidade total de picos e vales menores, quantidade total de picos e vales

maiores, maior distância entre dois pontos e a quantidade de cores encontradas na lesão. O descritor GLCM calculou 17 dessas características: contraste, correlação, energia e homogeneidade, que foram calculados sob a área lesionada nas 4 orientações, e entropia, somente em uma. E por fim, o LBP, composto por 256 atributos (MOURA *et al.*, 2015c).

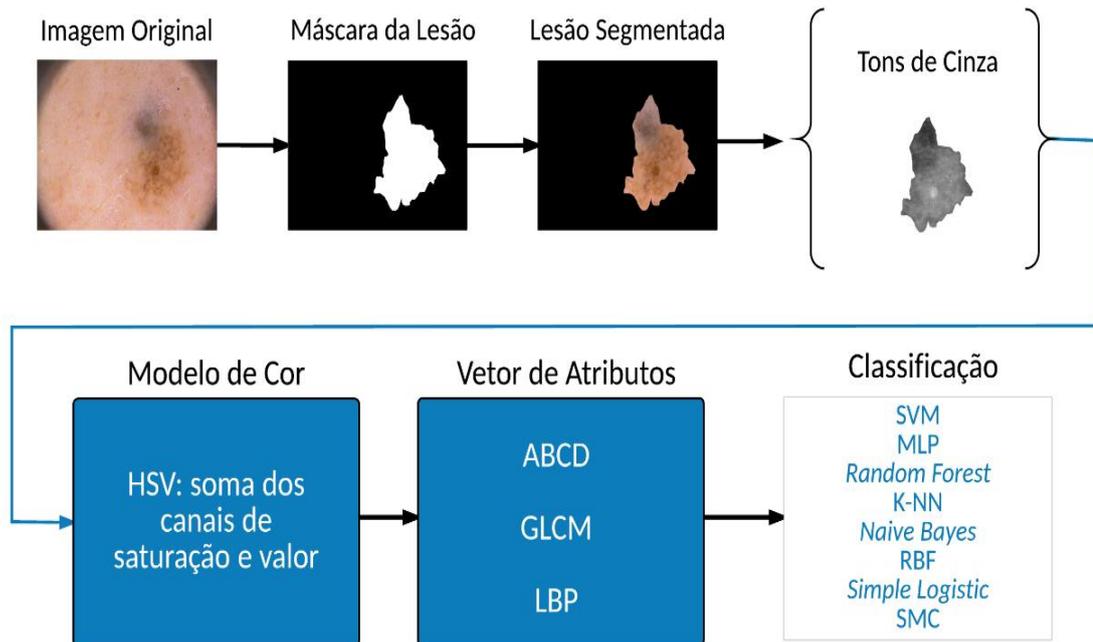


Figura 12 - Fluxograma do Experimento 3.

Experimento 4: Uma comparação entre os algoritmos GLCM, LBP, GLRLM e HOG foi feita com o modelo de cores HSV. Os testes foram feitos com cada componente do modelo e a soma entres eles. Por fim, para a classificação, o algoritmo MLP, que melhor se destacou, foi utilizado. A Figura 13 mostra o fluxograma desse experimento.

O vetor de atributos para cada um dos quatro descritores utilizados nesse experimento foi formado com diferentes atributos, de acordo suas características extraídas das imagens. No algoritmo GLCM, o vetor é formado por 5 atributos: contraste, correlação, energia, homogeneidade e entropia, calculados sob a área lesionada somente na orientação 0° . No algoritmo GLRLM, o resultado é um vetor formado por 44 atributos de acordo com as medidas estatísticas calculadas sob a imagem nas 4 orientações. Já no descritor HOG, ele é composto por 81 atributos e no descritor LBP, 256 atributos.

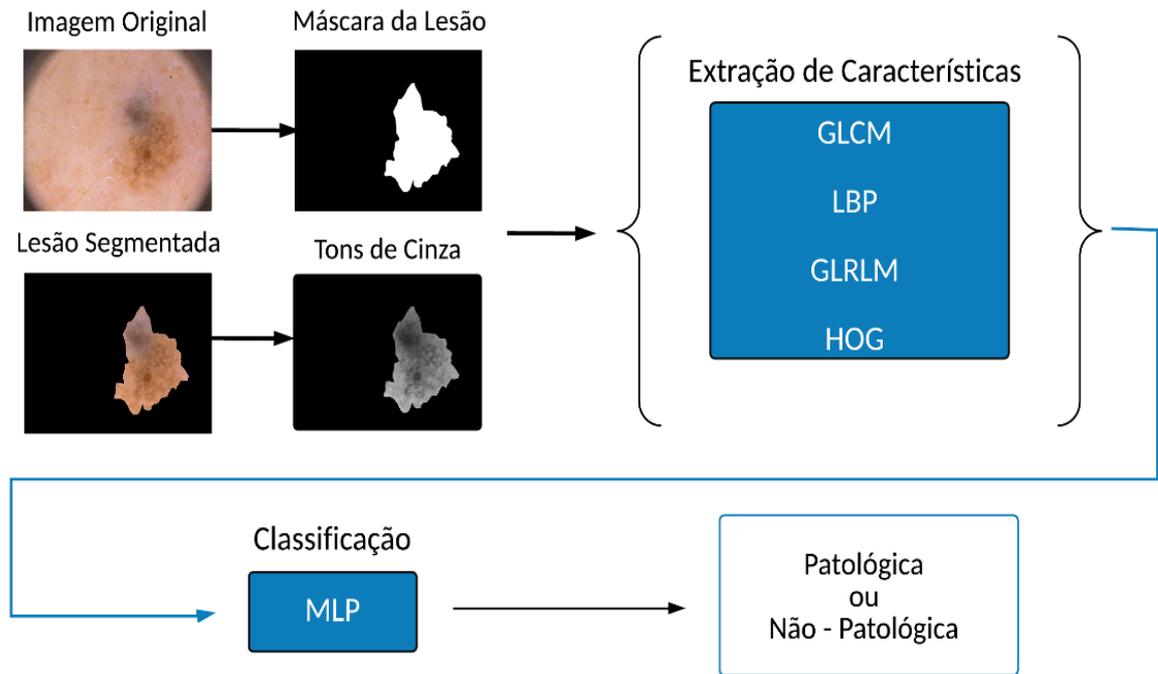


Figura 13 - Fluxograma do Experimento 4.

5 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados e discutidos os resultados encontrados com cada um dos experimentos. Para isso, nos testes, foram utilizadas 200 imagens, dentre estas, 40 melanomas e 160 não-melanomas da base de imagens PH². O método estatístico para gerar os resultados é o *k-fold cross-validation* ($k = 10$). Os resultados foram analisados de acordo com a Acurácia (A), a área sob a curva ROC (AUC) e o índice Kappa (K).

Nos resultados dos experimentos, a letra D nas tabelas é utilizada para representar o novo componente gerado a partir da distância euclidiana entre dois componentes. O símbolo “+” é utilizado para representar a resultante entre a soma de dois componentes de cores.

5.1 Resultados para o Experimento 1

A regra ABCD foi utilizada para a extração de características de lesões de pele, sendo o atributo Cor testado com diferentes modelos de cores. Nos testes, foram obtidos nove resultados para cada modelo: seus componentes, a soma e a distância euclidiana entre eles (de dois em dois). Assim, como utilizou-se cinco modelos de cores, 45 resultados foram obtidos, totalizando 270, por terem sido utilizados seis classificadores. Por motivo de conveniência, serão mostrados somente os melhores resultados de cada modelo de cor para cada classificador.

A Tabela 2 mostra os resultados obtidos com o modelo de cores RGB. Pode-se observar que o melhor resultado foi obtido com a soma dos canais vermelho e azul e o classificador *Random Forest*, com um índice Kappa de 0,72.

Tabela 2 - Melhores resultados para o modelo de cores RGB.

	VP	FP	FN	VN	K	AUC	A
R+G e MLP	155	5	14	26	0,67	0,86	0,90
R e RBF	157	3	15	25	0,68	0,87	0,91
R+B e RF	157	3	13	27	0,72	0,86	0,92
D(R,B) e LL	158	2	16	24	0,67	0,79	0,91
D(R,B) e SVM	159	1	22	18	0,55	0,72	0,88
G+B e K-NN	153	7	13	27	0,66	0,81	0,90

Os melhores resultados obtidos com o modelo de cores HSV são apresentados na Tabela 3. A soma dos canais de saturação e valor com o

classificador MLP obtiveram um resultado “Excelente” de acordo com a Tabela 1, com um índice Kappa maior que 0,8. Além disso, a taxa de acurácia e a área sob a curva ROC foram melhores em relação aos demais resultados para o modelo de cores HSV.

Tabela 3 - Melhores resultados para o modelo de cores HSV.

	VP	FP	FN	VN	K	AUC	A
S+V e MLP	158	2	9	31	0,81	0,96	0,94
S+V e RBF	154	6	9	31	0,75	0,96	0,92
H e RF	156	4	11	29	0,74	0,92	0,92
S+V e LL	155	5	9	31	0,77	0,87	0,93
S+V e SVM	157	3	12	28	0,74	0,84	0,92
S+V e K-NN	154	6	11	29	0,72	0,84	0,91

O modelo de cores CMY apresentou resultados satisfatórios para a extração de características e classificação (Tabela 4). Foi obtido um índice Kappa de 0,71 com o canal ciano e o classificador *Random Forest*. A área sob a curva ROC mostrou a robustez do classificador com uma taxa de 0,90.

Tabela 4 - Melhores resultados para o modelo de cores CMY.

	VP	FP	FN	VN	K	AUC	A
M e MLP	157	3	17	23	0,64	0,86	0,90
C e RBF	157	3	14	26	0,70	0,90	0,91
C e RF	156	4	13	27	0,71	0,90	0,91
C e LL	158	2	15	25	0,69	0,80	0,91
C e SVM	160	0	23	17	0,54	0,71	0,88
D(M,Y) e NN	150	10	17	23	0,54	0,75	0,86

A Tabela 5 mostra os melhores resultados obtidos utilizando o modelo de cores L*u*v. Pode-se observar que o melhor resultado foi um índice Kappa de 0,75. Esse resultado foi obtido a partir do uso do canal de cromaticidade v e o classificador MLP. O pior resultado foi obtido com a cromaticidade v e o classificador K-NN com um índice Kappa 0,55.

Tabela 5 - Melhores resultados para o modelo de cores L*u*v.

	VP	FP	FN	VN	K	AUC	A
v e MLP	155	5	10	30	0,75	0,88	0,92
v e RBF	151	9	11	29	0,68	0,93	0,90
u e RF	154	6	14	26	0,66	0,90	0,90
v e LL	152	8	10	30	0,71	0,85	0,91
v e SVM	150	10	11	29	0,66	0,83	0,89
v e K-NN	149	11	16	24	0,55	0,76	0,86

Os resultados para o modelo de cores YCbCr são apresentados na Tabela 6. Observa-se que o melhor resultado foi obtido com a soma entre o canal da luminância e o canal correspondente a crominância da diferença azul. Tal resultado foi obtido com o classificador Random Forest e obteve um índice Kappa de 0,74.

Tabela 6 - Melhores resultados para o modelo de cores YCbCr.

	VP	FP	FN	VN	K	AUC	A
Y+Cr e MLP	156	4	16	24	0,64	0,82	0,90
Y+Cr e RBF	156	4	13	27	0,71	0,87	0,91
Y+Cr e RF	157	3	12	28	0,74	0,88	0,92
Y+Cr e LL	158	2	17	23	0,65	0,78	0,90
Y+Cr e SVM	159	1	20	20	0,60	0,74	0,89
Y+Cb e K-NN	149	11	16	24	0,55	0,76	0,86

Os classificadores alcançaram resultados satisfatórios, porém, o MLP se destacou. Além disso, pode ser observado que o modelo de cores HSV obteve maior sucesso para a extração de características em imagens de lesões de pele, apresentando uma acurácia de 0,94 e um índice Kappa igual a 0,81, considerado excelente. Isto foi possível a partir da utilização do componente gerado pela soma dos canais de saturação e valor.

5.2 Resultados para o Experimento 2

O atributo Cor da regra ABCD e a GLCM foram utilizados e testados no modelo de cores HSV. Os testes foram feitos com cada componente do modelo e a soma entre eles, totalizando seis resultados encontrados para cada um dos três classificadores utilizados. Os resultados obtidos com o classificador SVM são apresentados na Tabela 7. Pode-se observar que o melhor resultado é encontrado a partir da soma dos canais S e V (S + V) do modelo de cores HSV, com uma acurácia de 0,91 e um índice Kappa de 0,69.

Os resultados encontrados com a utilização do classificador MLP são mostrados na Tabela 8. A soma dos canais S e V do modelo de cores HSV também obtiveram um melhor resultado atingindo uma acurácia de 0,92 e um índice Kappa de 0,75. No entanto, com o classificador *Random Forest*, apresentado na Tabela 9, o melhor resultado alcançado é devido a utilização do canal H, que obteve uma acurácia de 0,89 e um índice Kappa de 0,65.

Tabela 7 - Resultados para o classificador SVM.

	VP	FP	FN	VN	K	AUC	A
H	152	8	14	26	0,63	0,80	0,89
S	155	5	16	24	0,63	0,78	0,89
V	156	4	15	25	0,67	0,80	0,90
H + S	153	7	13	27	0,67	0,82	0,90
H + V	156	4	24	16	0,46	0,69	0,86
S + V	156	4	14	26	0,69	0,81	0,91

Tabela 8 - Resultados para o classificador MLP.

	VP	FP	FN	VN	K	AUC	A
H	151	9	10	30	0,70	0,92	0,90
S	150	10	13	27	0,63	0,90	0,88
V	152	8	16	24	0,59	0,90	0,88
H + S	150	10	14	26	0,61	0,91	0,88
H + V	149	11	16	24	0,56	0,87	0,86
S + V	155	5	10	30	0,75	0,94	0,92

Tabela 9 - Resultados para o classificador Random Forest.

	VP	FP	FN	VN	K	AUC	A
H	150	10	12	28	0,65	0,91	0,89
S	150	10	12	28	0,50	0,91	0,89
V	154	6	15	25	0,64	0,90	0,89
H + S	150	10	12	28	0,65	0,90	0,89
H + V	150	10	17	23	0,55	0,87	0,86
S + V	150	10	14	26	0,61	0,91	0,88

Os três classificadores alcançaram resultados satisfatórios, porém, o MLP também se destacou, com uma área sob a curva ROC de 0,94. Além disso, pode ser observado que o componente gerado pela soma dos canais S e V do modelo de cores HSV obteve novamente maior sucesso para extração de características em lesões de pele. Ela apresentou uma acurácia de 0,92 e um índice Kappa igual a 0,75 na classificação.

5.3 Resultados para o Experimento 3

Neste experimento, o vetor composto pelas características das imagens de lesão de pele foi obtido pelo uso, em conjunto, dos descritores ABCD, GLCM e LBP com o componente gerado pela soma dos canais de saturação e valor do modelo de

cores HSV. A escolha desse componente pode ser explicada pelos resultados que foram alcançados com a sua utilização nos experimentos anteriores.

A Tabela 10 apresenta os resultados obtidos desse experimento para sete classificadores: SVM, *Naives Bayes*, K-NN, *Random Forest*, RBF, MLP, *Simple Logistic*. Pode-se observar que eles alcançaram resultados satisfatórios, porém, os classificadores RBF, MLP e *Simple Logistic*, destacados na Tabela 10, foram melhores, atingindo uma área sob a curva ROC de 0,93, 0,95 e 0,96, respectivamente.

Dessa maneira, ainda nesse experimento, foram realizados testes através da combinação dos classificadores RBF, MLP e *Simple Logistic* no SMC, com o objetivo de melhorar os resultados. O estudo de SMC's é necessário, visto que não há um único classificador que seja considerado ideal para todos os problemas (PONTI JUNIOR, 2011).

A Tabela 11 mostra os resultados dessa combinação. Ela foi testada pela utilização de quatro estratégias: Votação Majoritária (VM), Média de Probabilidades (MP), Produto de Probabilidades (PP) e Probabilidade Máxima (PM). Esta última estratégia, destacada na Tabela 11, obteve o melhor resultado para a classificação de imagens de lesão de pele, alcançando uma acurácia de 0,93 e um índice Kappa de 0,76.

Tabela 10 - Resultados para a classificação das imagens de lesão de pele com os descritores ABCD, GLCM e LBP.

	VP	FP	FN	VN	K	AUC	A
SVM	155	5	37	3	0,06	0,52	0,79
<i>Naive Bayes</i>	143	17	17	23	0,47	0,77	0,83
K-NN	147	13	13	27	0,59	0,80	0,87
<i>Random Forest</i>	149	11	11	29	0,66	0,92	0,89
RBF	150	10	11	29	0,67	0,93	0,89
MLP	149	11	10	30	0,67	0,95	0,89
<i>Simple Logistic</i>	154	6	14	26	0,66	0,96	0,90

Tabela 11 - Resultados para a classificação das lesões de pele com a combinação dos classificadores: RBF, MLP e *Simple Logistic*.

	VP	FP	FN	VN	K	AUC	A
VM	152	8	10	30	0,71	0,85	0,91
MP	154	6	11	29	0,72	0,96	0,91
PP	155	5	11	29	0,73	0,96	0,92
PM	157	3	11	29	0,76	0,96	0,93

5.4 Resultados para o Experimento 4

Os descritores GLCM, GLRLM, HOG e LBP foram comparados com a utilização do modelo de cores HSV, seus componentes e a soma entre eles. Para a classificação das imagens utilizou-se o algoritmo MLP. Os resultados obtidos com o descritor GLCM são apresentados na Tabela 12. Pode-se observar que o melhor resultado é encontrado a partir do componente gerado pela soma dos canais H e V, com uma acurácia de 0,90 e um índice Kappa de 0,67.

Tabela 12 - Resultados para o algoritmo GLCM.

	VP	FP	FN	VN	K	AUC	A
H	149	11	13	27	0,62	0,92	0,88
S	152	8	14	26	0,64	0,90	0,89
V	155	5	22	18	0,5	0,84	0,86
H+S	142	18	23	17	0,33	0,82	0,79
H+V	156	4	15	25	0,67	0,87	0,90
S+V	149	11	26	14	0,33	0,88	0,81

O descritor GLRLM, apresentado na Tabela 13, com a soma dos canais H e S do modelo de cores HSV obtiveram um melhor resultado, alcançando uma acurácia de 0,90 e um índice Kappa de 0,70, se mostrando mais eficiente que a GLCM.

Tabela 13 - Resultados para o algoritmo GLRLM.

	VP	FP	FN	VN	K	AUC	A
H	141	19	16	24	0,47	0,88	0,82
S	149	11	13	27	0,62	0,88	0,88
V	147	13	15	25	0,55	0,86	0,86
H+S	151	9	10	30	0,70	0,92	0,90
H+V	154	6	18	22	0,58	0,88	0,88
S+V	149	11	19	21	0,49	0,89	0,85

O descritor HOG obteve uma acurácia de 0,91 e um índice Kappa de 0,73 como melhor resultado a partir do canal H, como pode ser observado na Tabela 14. Já o descritor LBP, não atingiu os resultados esperados, alcançando uma acurácia de apenas 0,89 e um Kappa de 0,66 com a utilização, mais uma vez, do canal H do modelo de cores HSV (Tabela 15).

Os quatro descritores alcançaram resultados satisfatórios, porém, o descritor HOG se destacou. Além disso, pode ser observado que para esse descritor a utilização do canal H do modelo de cores HSV foi a que obteve maior sucesso para

extração de características em lesões de pele, proporcionando uma maior taxa de acerto.

Tabela 14 - Resultados para o algoritmo HOG.

	VP	FP	FN	VN	K	AUC	A
H	152	8	9	31	0,73	0,95	0,91
S	146	14	11	29	0,62	0,89	0,87
V	145	15	14	26	0,55	0,89	0,85
H+S	148	12	9	31	0,68	0,95	0,89
H+V	147	13	15	25	0,55	0,90	0,86
S+V	152	8	14	26	0,64	0,94	0,89

Tabela 15 - Resultados para o algoritmo LBP.

	VP	FP	FN	VN	K	AUC	A
H	149	11	11	29	0,66	0,95	0,89
S	147	13	12	28	0,61	0,87	0,87
V	139	21	17	23	0,43	0,80	0,81
H+S	140	20	14	26	0,50	0,83	0,83
H+V	137	23	16	24	0,43	0,80	0,80
S+V	142	18	12	28	0,56	0,88	0,85

5.5 Discussões

No primeiro experimento, os resultados mostrados exemplificam o quão importante é a análise de diferentes modelos de cores para extração de características de lesões de pele. Isso se deve ao fato das lesões malignas terem uma distribuição de cores diferente das lesões benignas. O modelo de cor que melhor diferenciou as lesões foi o HSV (matiz, saturação, valor), com a soma entre os canais de saturação e valor. Entretanto, os outros modelos de cor, apesar de alcançarem resultados considerados bom, não apresentaram tanta eficácia como o HSV.

No segundo experimento, o descritor de textura GLCM, que foi utilizado em conjunto com o atributo Cor para a extração de características, não obteve resultados satisfatórios mesmo utilizando o modelo de cor HSV, em que foi testado seus componentes e a soma entre eles. Assim, embora um índice Kappa de 0,75 com o classificador MLP tenha sido atingido, obtendo um desempenho “Muito Bom” de acordo com a Tabela 1, o experimento anterior ainda foi melhor, com um Kappa de 0,81.

No terceiro experimento, em que outros descritores de textura e a regra ABCD foram empregados para a extração de características, os resultados obtidos

também foram satisfatórios. Entretanto, a partir da análise dos mesmos, concluiu-se que descritores que utilizam informações de textura não são suficientemente bons na extração de características em determinados problemas de reconhecimento de padrões.

Por fim, no último experimento, os descritores GLCM, GLRLM, HOG e LBP foram comparados com o classificador MLP. O descritor LBP atingiu os menores resultados de acurácia e índice Kappa (0,89 e 0,66), assim como a GLCM e GLRLM, descritores de textura, que provaram mais uma vez não serem eficientes para extração de características de lesão de pele. O HOG, porém, alcançou uma taxa de acerto (acurácia) de 0,91 e um índice Kappa de 0,73, considerado “Muito Bom”.

A partir dos experimentos, pode-se observar que o melhor resultado foi obtido com a utilização do descritor ABCD para a extração de características, e o algoritmo MLP para a classificação. A acurácia foi de 0,94 e o índice Kappa de 0,81, classificando a solução como “Excelente”. Dentre todos os resultados, esse foi o único com a classificação máxima em relação ao índice. Nesse sentido, quanto aos classificadores, o algoritmo MLP apesar de não ser o único que obteve uma área sob a curva ROC igual a 0,96, foi o classificador que apresentou os melhores resultados e obteve a qualidade máxima do nível de precisão da classificação de acordo com o índice Kappa.

6 CONSIDERAÇÕES FINAIS

A evolução do Processamento Digital de Imagens (PDI) pode ser vista nas mais diferentes áreas existentes, e sua aplicação está cada vez maior. Na área médica, por exemplo, o diagnóstico de doenças por PDI traz rapidez, eficiência e redução de custo, já que não é necessário um profissional da área executar os algoritmos responsáveis pela detecção da patologia.

Este trabalho mostrou a extração de características de lesões de pele utilizando os algoritmos ABCD, LBP, GLCM, GLRLM e HOG através de diversos experimentos. Além disso, os modelos de cores, seus componentes e combinações entre eles foram testados a fim de se encontrar o melhor resultado.

A acurácia, a área sob a curva ROC e o índice Kappa foram as métricas utilizadas nesse trabalho. Elas são apropriadas para a avaliação dos resultados de cada experimento e teste que foi realizado. Isto porque avaliam o desempenho dos algoritmos de classificação, retornando bons resultados somente quando a classificação teve boas taxas de acerto.

Os resultados mostram que a regra ABCD descreve a imagem suficientemente bem para o problema em questão. Além disso, o modelo de cor que melhor diferenciou as lesões foi o HSV, com ênfase para o componente gerado pela soma dos canais de saturação e valor. Dentre todos os resultados obtidos, a utilização desse componente com o classificador MLP obtiveram um índice Kappa maior que 0,8, ou seja, excelente. A eficiência desse canal pode ser explicada pelo valor do atributo Cor da regra ABCD.

6.1 Trabalhos Futuros

Como trabalhos futuros, almeja-se utilizar novos descritores para a extração de características em imagens de lesões de pele, tais como a Transformada de *Wavelet Packet*, o descritor de Fourier e o *Speeded Up Robust Features* (SURF), e ainda novos classificadores e modelos de cores. Os algoritmos serão testados com outras bases de imagens para melhor verificação de sua eficiência. Além disso, a importância das características extraídas serão analisadas através dos chamados PCA (*Principal Components Analysis* – Análise de Componentes Principais). E por

fim, será feita a comparação dos resultados obtidos com outros métodos da literatura.

6.2 Publicações Obtidas

MOURA, N. H.; MOURA, G. C.; SILVA, R. R. V.; SILVA, E. S.; VERAS, R. M. S. **Classificação de Lesões de Pele Utilizando Atributos de Cor e Textura**. Workshop de Informática Médica – WIM, 2015.

MOURA, N. H.; SILVA, R. R. V.; ARAÚJO, F. H. D. **Extração de Atributos e Classificação de Lesões de Pele Utilizando Combinação de Componentes de Modelos de Cores**. Revista de Sistemas e Computação, v. 5, n. 1, 2015.

MOURA, N. H.; SILVA, R. R. V.; SILVA, E. S.; MOURA, G. C. **Combinação de Componentes de Cor para Extração de Atributos em Lesões de Pele**. Escola Regional de Informática do Piauí – ERIPI, 2015.

MOURA, N. H.; SILVA, R. R. V.; SILVA, E. S.; MOURA, G. C.; VERAS, R. M. S. **Deteção Automática de Lesões de Pele em Imagens Dermatoscópicas**. Simpósio Brasileiro de Automação Inteligente – SBAI, 2015.

REFERÊNCIAS

- AMERICAN CANCER SOCIETY (ACS). **Cancer facts & figures 2015**. 2015. Disponível em: <<http://www.cancer.org/acs/groups/content/@editorial/documents/document/acspc-044552.pdf>>. Acesso em: 02 set. 2015.
- ARAÚJO, A. F.; TAVARES, J. M. R. S.; OLIVEIRA, R. B.; ROSSETTI, R. B.; MARRANGHELLO, N.; PEREIRA, A. S. **Análise e Caracterização de Lesões de Pele para Auxílio ao Diagnóstico Médico**. In: NEVES, L. A. P.; NETO, H. V.; GONZAGA, A. (Eds.). *Avanços em Visão Computacional*. Paraná: omnipax, p. 27-46, 2012.
- BARALDI, A.; PARMIGGIANI, F. **An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters**. *IEEE Transactions on Geoscience and Remote Sensing*, v. 33, n. 2, p. 293-304, 1995.
- BARCELOS, C. A. Z.; BOAVENTURA, M.; SILVA JÚNIOR, E. C. **A well-balanced flow equation for noise removal and edge detection**. *IEEE Transactions on Image Processing*, v. 12, n. 7, p. 751-763, 2003.
- BREIMAN, L. **Random forests**. *Machine Learning*, v. 45, n. 1, p. 5-32, 2001.
- CAVALCANTI, P. G.; SCHARCANSKI, J.; BARANOSKI, G. V. G. **A two-stage approach for discriminating melanocytic skin lesions using standard cameras**. *Expert Systems with Applications*, v. 40, n. 10, p. 4054-4064, 2013.
- CHU, A.; SEHGAL, C. M.; GREENLEAF, J. F. **Use of gray value distribution of run lengths for texture analysis**. *Pattern Recognition Letters*, v. 11, n. 6, p. 415-419, 1990.
- CORTES, C.; VAPNIK, V. **Support-vector networks**. *Machine learning*, v. 20, n. 3, p. 273-297, 1995.
- COVER, T. M. **Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition**. *IEEE Transactions on Electronic Computers*, n. 3, p. 326-334, 1965.
- DALAL, N.; TRIGGS, B. **Histograms of oriented gradients for human detection**. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, v. 1, p. 886-893, 2005.
- FAN, R. E.; CHANG, K. W.; HSIEH, C. J.; WANG, X. R.; LIN, C. J. **LIBLINEAR: A library for large linear classification**. *Journal of Machine Learning Research*, v. 9, p. 1871-1874, 2008.
- FORNACIALI, M.; AVILA, S.; CARVALHO, M.; VALLE, E. **Statistical Learning Approach for Robust Melanoma Screening**. *Conference on Graphics, Patterns and Images (SIBGRAPI)*, p. 319-326, 2014.

FRASER, B.; MURPHY, C.; BUNTING, F. **Real world color management**. 2ª ed. New Jersey: Pearson Education, 2004. 608 p.

GALLOWAY, M. M. **Texture analysis using gray level run lengths**. Computer Graphics and Image Processing, v. 4, n. 2, p. 172-179, 1975.

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens**. 3ª ed. São Paulo: Pearson Prentice Hall, 2010. 640 p.

HARALICK, R.; SHANMUGAM, K.; DINSTEN, I. **Textural features for image classification**. IEEE Transactions on Systems, Man and Cybernetics, n. 6, p. 610-621, 1973.

HAYKIN, S. **Neural Networks and Learning Machines**. 3ª ed. New Jersey: Prentice Hall, 2008. 936 p.

INSTITUTO NACIONAL DE CÂNCER (INCA). **O que é o câncer?**. 2015. Disponível em: <http://www1.inca.gov.br/conteudo_view.asp?id=322>. Acesso em: 02 set. 2015.

LACY, K.; ALWAN, W. **Skin cancer**. Medicine, v. 41, n. 7, p. 402-405, 2013.

LANDWEHR, N.; HALL, M.; FRANK, E. **Logistic model trees**. Machine Learning, v.59, n. 1-2, p. 161-205, 2005.

MANNING, C. D.; RAGHAVAN, P.; SCHÜTZE, H. **Introduction to Information Retrieval**. 1ª ed. Cambridge: Cambridge University Press, 2008. 506 p.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999. 331 p.

MENDONÇA, T.; FERREIRA, P. M.; MARQUES, J. S.; MARCAL, A. R. S.; ROZEIRA, J. **PH² - A dermoscopic image database for research and benchmarking**. Annual International Conference of the IEEE Engineering in Medicine and Biology Society, p. 5437-5440, 2013.

MOURA, N. H.; MOURA, G. C.; SILVA, R. R. V.; SILVA, E. S.; VERAS, R. M. S. **Classificação de Lesões de Pele Utilizando Atributos de Cor e Textura**. Workshop de Informática Médica – WIM, 2015b.

MOURA, N. H.; SILVA, R. R. V.; ARAÚJO, F. H. D. **Extração de Atributos e Classificação de Lesões de Pele Utilizando Combinação de Componentes de Modelos de Cores**. Revista de Sistemas e Computação, v. 5, n. 1, 2015.

MOURA, N. H.; SILVA, R. R. V.; SILVA, E. S.; MOURA, G. C. **Combinação de Componentes de Cor para Extração de Atributos em Lesões de Pele**. Escola Regional de Informática do Piauí – ERIPI, 2015a.

MOURA, N. H.; SILVA, R. R. V.; SILVA, E. S.; MOURA, G. C.; VERAS, R. M. S. **Deteção Automática de Lesões de Pele em Imagens Dermatoscópicas**. Simpósio Brasileiro de Automação Inteligente – SBAI, 2015c.

OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. **A comparative study of texture measures with classification based on featured distributions**. Pattern recognition, v. 29, n. 1, p. 51-59, 1996.

PAROLIN, A., HERZER, E.; JUNG C. R. **Semi-automated diagnosis of melanoma through the analysis of dermatological images**. Conference on Graphics, Patterns and Images (SIBGRAPI), p. 71-78, 2010.

PONTI JUNIOR, M. P. **Combining classifiers**: From the creation of ensembles to the decision fusion. Conference on Graphics, Patterns and Images Tutoriais (SIBGRAPI-T), p. 1-10, 2011.

ROSENFELD, G. H.; FITZPATRICK-LINS, K. A. **A coefficient of agreement as a measure of thematic classification accuracy**. Photogrammetric Engineering and Remote Sensing, v. 52, p. 223-227, 1986.

RUSS, J. C. **The image processing handbook**. 6ª ed. Florida: CRC Press, 2011. 885 p.

SAID, Y.; ATRI, M.; TOURKI, R. **Human detection based on integral Histograms of Oriented Gradients and SVM**. IEEE International Conference on Communications, Computing and Control Applications, p. 1-5, 2011.

SILVA JÚNIOR, E. R. **Investigação de Técnicas de Extração e Seleção de Características e Classificadores Aplicados ao Problema de Classificação de Dígitos Manuscritos de Imagens de Documentos Históricos**. 2007. 51 f. Monografia (Bacharelado em Engenharia da Computação) – Escola Politécnica de Pernambuco, Universidade Federal de Pernambuco, Pernambuco. 2007.

SILVA, M. A. T. B. **Uso de Matrizes de Co-ocorrências para Classificação Automática de Imagens de Cana-de-açúcar**. 2013. 75 f. Monografia (Bacharelado em Ciência da Computação) – Universidade Federal de Lavras, Minas Gerais. 2013.

SILVA, R. R. V. **Detecção do Uso de Capacete por Motociclistas em Vias Públicas**. 2014. 100 f. Dissertação (Mestrado em Ciência da Computação) – Centro de Ciências da Natureza, Universidade Federal do Piauí, Piauí. 2014.

SILVA, R. R. V.; AIRES, K. R. T.; VERAS, R. M. S. **Helmet Detection on Motorcyclists Using Image Descriptors and Classifiers**. Conference on Graphics, Patterns and Images (SIBGRAPI-T), p. 141-148, 2014.

SKIN CANCER FOUNDATION. **Skin cancer facts**. 2015. Disponível em: <<http://www.skincancer.org/skin-cancer-information/skin-cancer-facts#melanoma>>. Acesso em: 02 set. 2015.

SOARES, H. B. **Análise e classificação de imagens de lesões da pele por atributos de cor, forma e textura utilizando máquina de vetor de suporte**. 2008. 180 f. Tese (Doutorado em Engenharia Elétrica e de Computação) – Centro de Tecnologia, Universidade Federal do Rio Grande do Norte, Rio Grande do Norte. 2008.

SOBEL, I. E. **Camara Models and Machine Perception**. Tese (Ph.D dissertation) – Stanford Computer Science Department, Palo Alto, California, 1970.

SOCIEDADE BRASILEIRA DE DERMATOLOGIA (SBD). **Câncer da pele**. 2014. Disponível em: <<http://www.sbd.org.br/doencas/cancer-da-pele/>>. Acesso em: 02 set. 2015.

SUMNER, M.; FRANK, E.; HALL, M. **Speeding up logistic model tree induction**. Conference on Principles and Practice of Knowledge Discovery in Databases, p. 675-683, 2005.

SURULIANDI, A.; MEENA, K.; REENA ROSE, R. **Local binary pattern and its derivatives for face recognition**. IET Computer Vision, v. 6, n. 5, p. 480-488, 2012.

VERAS, R. M.S.; MACHADO, V. P.; SILVA, R. R. V.; ARAUJO, F. H.; AIRES, K. R. T. **Aplicação de Aprendizagem de Máquina para Classificação Automática de Retinas Patológicas**. Anais do X Congresso Brasileiro de Inteligência Computacional, 2011.

WORLD HEALTH ORGANIZATION (WHO). **How common is skin cancer?**. 2015. Disponível em: <<http://www.who.int/uv/faq/skincancer/en/index1.html>>. Acesso em: 02 set. 2015.



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

Identificação do Tipo de Documento

- Tese
 Dissertação
 Monografia
 Artigo

Eu, **Nayara Holanda de Moura**, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação **Classificação Automática de Lesões de Pele Usando Descritores de Forma, Cor e Textura e Múltiplos Classificadores** de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI 15 de fevereiro de 2016.

Nayara Holanda de Moura
Assinatura